



TRABAJO DE DIPLOMA

En opción al Título de Ingeniero(a) en Automática

Autora

Angela Gabriela Carballo Alpizar

Tutores

Dra.C. Daily Milanés Hermosilla

Dr. C. Rafael Arturo Trujillo Codorníu

Dr.C. Leonardo Peña Pupo

Noviembre, 2023



**UNIVERSIDAD
DE ORIENTE**

Facultad de Ingeniería Eléctrica

Departamento de Automática

TRABAJO DE DIPLOMA

Título

Detección de puntos calientes en generadores fotovoltaicos a partir de termografía infrarroja y técnicas de aprendizaje profundo.

Autora

Angela Gabriela Carballo Alpizar

Tutores

Dra.C. Daily Milanés Hermosilla

Dr. C. Rafael Arturo Trujillo Codorniú

Dr.C. Leonardo Peña Pupo

Noviembre, 2023

Hago constar que el presente Trabajo de Diploma fue realizado en la Universidad de Oriente como parte de la culminación de estudios de la especialidad de Ingeniería en Automática, autorizando a que el mismo sea utilizado por la Institución para los fines que estime convenientes, tanto de forma parcial como total, y que además no podrá ser presentado en eventos, ni publicados sin autorización de la Universidad.

Nombre y firma del autor

Los abajo firmantes certificamos que el presente trabajo ha sido realizado según acuerdo de la dirección de nuestro centro y el mismo cumple con los requisitos que debe tener un trabajo de esta envergadura referido a la temática señalada.

Nombre y firma del autor

Nombre y firma del Tutor

Fecha

Nombre y firma del Jefe de Carrera

Fecha

Nombre y firma del Jefe de Departamento

Fecha

Dedicatoria

Dedico la presente investigación a mis padres María y Nono, a mi esposo Juan Carlos y a mi hermano Elie. La comprensión y el apoyo brindado fueron fundamentales para mí. ¡Muchísimas gracias, familia!

Agradecimientos

A mis padres, mi esposo y mi hermano, a mis abuelos, mis tíos y primos, a mis suegros, a mis cuñados, a toda mi familia.

A mis tutores, porque sus conocimientos y experiencia fueron pilares en esta investigación.

A la profesora Daily por su dedicación y apoyo en todo momento.

A todos los profesores de del Departamento de Automática por sus conocimientos y consejos durante estos cuatro años de carrera universitaria.

A mis compañeros de la Universidad de Oriente, gracias por todo.

A mis amigos Jorge, Amanda, Leticia, Indira, David, Enmanuel y Dayron, siempre incondicionales.

A mi amigo Gabriel.

Listado de imágenes

Figura 1. Estructura de un módulo PV	7
Figura 2. Fallos de degradación más significativos en módulos fotovoltaicos instalados en los últimos 10 años.....	10
Figura 3. Efectos de los puntos calientes en módulos PV. a) a pequeña escala, b) a gran escala.	11
Figura 4. Técnicas más comunes de detección realizadas a módulos fotovoltaicos con puntos calientes. a) Curva característica I-V, b) Prueba de electroluminiscencia, c) Termografía infrarroja.	12
Figura 5. Estructura de una red neuronal artificial	15
Figura 6. Modelo computacional de una neurona.....	15
Figura 7. Capa convolucional de una CNN	19
Figura 8. Capa de reducción con submuestreo máximo y promedio	19
Figura 9. Arquitectura AlexNet	20
Figura 10. Bloque tradicional de la arquitectura ResNet.....	21
Figura 11. Arquitecturas VGG. a) Modelo VGG-16. b) Modelo VGG-19.....	22
Figura 12. Diferencia entre los bloques residuales y los bloques residuales invertidos de la arquitectura MobileNet-v2	23
Figura 13. Algunas transformaciones en imágenes aplicando la técnica de aumento de datos	24
Figura 14. Modelo de red neuronal con 2 capas ocultas: a) sin <i>dropout</i> , b) adelgazada con <i>dropout</i>	25
Figura 15. Tecnología fotovoltaica en Cuba	28
Figura 16. Esquema general de la solución propuesta	31
Figura 17. Muestra representativa de las imágenes según la clase	32
Figura 18. Imagen de muestra y sus transformaciones aplicando la técnica de aumento de datos a la BD.....	34
Figura 19. Estructura general de la CNN propuesta basada en la arquitectura optimizada de AlexNet	37
Figura 20. Matriz de confusión. TP: Verdadero Positivo, TN: Verdadero Negativo, FP: Falso Positivo, FN: Falso Negativo	38

Figura 21. Representación de la técnica de retención repetida 20 veces	41
Figura 22. Distribución del conjunto de imágenes en los subconjuntos de entrenamiento, validación y prueba.....	42
Figura 23. Proceso de aprendizaje del modelo durante el entrenamiento con respecto al número de épocas: a) según las métricas de pérdida y tasa de aprendizaje, b) según los valores de exactitud en los subconjuntos de entrenamiento y validación	43
Figura 24. Matriz de confusión sobre el subconjunto de prueba.....	45
Figura 25. Visualización del método t-SNE: a) antes del entrenamiento, b) a la entrada de la segunda capa densa, c) a la entrada de la capa de clasificación....	46
Figura 26. Comparación entre las funciones de pérdida sobre el subconjunto de validación.....	49
Figura 27. Comparación entre los valores de exactitud obtenidos sobre el subconjunto de prueba.....	50

Listado de tablas

Tabla 1. Algunas funciones de activación de una ANN.	16
Tabla 2. Métodos basados en ML que han sido empleados para detectar puntos calientes.....	26
Tabla 3. Características de la base de datos InfraredSolarModules.....	33
Tabla 4. Transformaciones en la base de datos al aplicar la técnica de aumento de datos.	35
Tabla 5. Resultados obtenidos en la evaluación de la arquitectura propuesta sobre el subconjunto de prueba.	44
Tabla 6. Características de las bases de datos empleadas en ambas investigaciones.	48

Resumen

La energía solar fotovoltaica es actualmente una de las fuentes renovables de energía con mayor impacto en el desarrollo energético y tecnológico sostenible a escala global. Dentro de esta tendencia, Cuba apuesta al futuro con la incorporación de parques fotovoltaicos en la matriz energética, de modo que contribuyan a satisfacer gran parte de la demanda del sistema eléctrico nacional. Los puntos calientes constituyen uno de los defectos de degradación más peligrosos en los módulos fotovoltaicos y afectan gravemente la calidad de la energía generada. El presente informe analiza las técnicas más empleadas en la detección automática de puntos calientes en módulos fotovoltaicos empleando termografía infrarroja y aprendizaje profundo. Se refiere el estado del arte a partir de publicaciones científicas comprendidas entre los años 2018 a la actualidad, indexadas en bases de prestigio internacional para esta área de investigación. La situación actual y las limitaciones de las técnicas empleadas en Cuba para la detección de estos defectos quedan expuestas. Siguiendo las tendencias internacionales, se propone un método automático para la detección de puntos calientes a partir de termografía infrarroja empleando un modelo de redes neuronales profundas basado en la arquitectura AlexNet. Para lograr un mejor aprendizaje del modelo se implementan las técnicas de regularización de aumento de los datos, parada temprana y disminución de la tasa de aprendizaje durante el entrenamiento. Esta propuesta contribuirá a detectar y predecir con mayor efectividad la aparición de puntos calientes en módulos fotovoltaicos instalados en Cuba, en aras de elevar su eficiencia, rendimiento y vida útil.

Palabras claves: aprendizaje profundo, módulos fotovoltaicos, puntos calientes, termografía infrarroja.

Abstract

Photovoltaic solar energy is currently one of the renewable energy sources with the greatest impact on sustainable energy and technological development globally. Within this trend, Cuba is betting on the future with the incorporation of photovoltaic parks into the energy matrix, so that they contribute to satisfying a large part of the demand of the national electrical system. Hot spots constitute one of the most dangerous degradation defects in photovoltaic modules and seriously affect the quality of the generated energy. This report analyzes the most used techniques in automatically detecting hot spots in photovoltaic modules using infrared thermography and deep learning. The state of the art is referred to from scientific publications from 2018 to the present, indexed in internationally prestigious databases for this area of research. The current situation and the limitations of the techniques used in Cuba to detect these defects are exposed. Following international trends, an automatic method is proposed for hot spot detection from infrared thermography using a deep neural network model based on the AlexNet architecture. To achieve a better learning of the model, the regularization techniques of data augmentation, early stopping and decay of the learning rate are implemented during training. This proposal will contribute to detecting and predicting more effectively the appearance of hot spots in photovoltaic modules installed in Cuba, to increase their efficiency, performance, and useful life.

Key-words: *deep learning, hotspot, infrared thermography, photovoltaic module.*

ÍNDICE

Listado de imágenes	I
Listado de tablas	III
Resumen	IV
<i>Abstract</i>	V
INTRODUCCIÓN	1
CAPÍTULO 1: Fundamentos teóricos de la detección de puntos calientes en módulos fotovoltaicos.....	5
1.1 Tecnología fotovoltaica	5
1.1.1 Celdas fotovoltaicas.....	5
1.1.2 Módulos fotovoltaicos	6
1.1.3 Generadores fotovoltaicos	8
1.2 Fallos de degradación más comunes en módulos fotovoltaicos	9
1.2.1 Puntos calientes en módulos fotovoltaicos	10
1.3 Técnicas y métodos de detección de puntos calientes en módulos fotovoltaicos.....	11
1.4 Aprendizaje automático y aprendizaje profundo.....	13
1.5 Las redes neuronales artificiales y las redes neuronales profundas	14
1.5.1 Aprendizaje de las redes neuronales profundas	16
1.6 Redes neuronales convolucionales.....	18
1.6.1 Ejemplos de arquitecturas de redes neuronales convolucionales	20
1.6.2 Técnicas de regularización	23
1.7 Empleo de métodos automáticos en la detección de puntos calientes	26
1.8 Detección de puntos calientes en módulos fotovoltaicos en Cuba	28
Conclusiones parciales	29

CAPITULO 2. Arquitectura de red neuronal profunda para detectar puntos calientes en módulos fotovoltaicos.....	30
2.1 Propuesta de un método de detección automática de puntos calientes en módulos PV	30
2.2 Adquisición de los datos de entrada.....	31
2.2.1 Base de datos InfraredSolarModules	31
2.3 Preprocesamiento de los datos	32
2.3.1 Técnica de aumento de datos.....	33
2.4 Modelo de la red neuronal.....	35
2.4.1 Arquitectura <i>AlexNet</i> empleada	35
2.4.2 Métricas empleadas para la evaluación del modelo.....	37
2.4.3 Método de visualización para la evaluación del modelo.....	38
2.5 Descripción de los experimentos realizados.....	40
2.6 Resultados de los experimentos	42
2.7 Discusión de los resultados.....	46
2.8 Conclusiones parciales	50
CONCLUSIONES	52
RECOMENDACIONES	53
BIBLIOGRAFÍA	54
ANEXOS.....	60

INTRODUCCIÓN

Las formas convencionales de generación de energía eléctrica a partir combustibles fósiles han demostrado ser la principal causa del calentamiento global y del cambio climático. Las emisiones de dióxido de carbono que se liberan en los procesos de combustión industrial apuntan a la necesidad de revertir esta situación de emergencia climática y construir una sociedad y una economía más autónomas, capaces de resistir frente a los riesgos energéticos. Particularmente, la descarbonización progresiva del planeta representa un cambio de paradigma de vital importancia que pretende el abandono paulatino del carbono garantizando la estabilidad y la resiliencia energética.

Las fuentes renovables de energía (FRE) han resultado ser una alternativa sostenible y limpia al desarrollo energético y tecnológico a escala global, contribuyendo así a la transición hacia una matriz energética más sostenible, al ahorro de costos y la estabilidad de precios en el mercado, haciéndolas más asequibles y competitivas. Dentro de las FRE más destacadas por la madurez de su tecnología y las ganancias a largo plazo que genera, se encuentra la energía solar fotovoltaica. Según las estadísticas de capacidad de generación renovable proporcionadas por la Agencia Internacional de Energía Renovable (IRENA) [1], para el año 2021 la energía solar experimentó un crecimiento significativo de un 22% liderando la capacidad de expansión de las FRE a nivel mundial y, reportes de años posteriores han demostrado que ante la demanda de producción de energía eléctrica, su desarrollo ha ido en ascenso.

Una de las tecnologías claves más empleadas en la generación de energía eléctrica a partir del sol son los módulos fotovoltaicos (PV, del inglés *Photo-voltaic*) o paneles solares, que transforman directamente la energía solar en electricidad. Debido a la eficiencia y la alternativa que proporcionan, poseen una amplia variedad de aplicaciones en diferentes sectores, desde la electrificación de viviendas alejadas de la red eléctrica hasta la generación de electricidad para hoteles, señales de tráfico y navegación aérea e incluso equipos remotos de adquisición y transmisión de datos.

En Cuba, desde el año 2019 la energía solar PV es la FRE que mejores resultados ha presentado en el país, siendo la segunda con mayor participación en la matriz eléctrica nacional [2]. Actualmente cuenta con un número considerable de parques PV de pequeño tamaño instalados a lo largo de toda la Isla [3]. Aunque a día de hoy ayudan a aliviar parte de las demandas del sistema energético nacional, el buen desempeño de la industria PV es clave para que el país pueda ir revirtiendo su dependencia a los combustibles fósiles y ganando autonomía energética en situaciones de contingencia. Resulta entonces imprescindible garantizar el correcto funcionamiento de los módulos PV, de modo que se pueda obtener de estos la máxima capacidad de generación y en conjunto satisfacer la demanda energética con un mínimo de pérdidas.

Debido a las condiciones de funcionamiento de los módulos PV en exteriores, estos se encuentran expuestos a múltiples factores que pueden acelerar sus índices de degradación, como son: las microfracturas y microgrietas, la delaminación, los fallos de conexión, los puntos calientes, entre otros. Respecto a los puntos calientes, es importante señalar que estos constituyen uno de los defectos más peligrosos en estos dispositivos, afectando gravemente la calidad de la energía generada. Los métodos de detección y prevención de estos son diversos, y abarcan desde la simple inspección visual hasta las técnicas de detección automáticas. El desarrollo de estas últimas y sus vías de implementación han sido de los temas más abordados en la literatura, siendo el uso de la inteligencia artificial la tendencia en las investigaciones de esta área de conocimiento [4].

La favorable situación geográfica de Cuba ha permitido que la construcción de parques PV constituya una vía de generación de electricidad cada vez más factible para el país. En estos sistemas generadores, la detección de defectos de degradación como los puntos calientes, se realiza empleando técnicas de inspección visual a partir de termografía infrarroja y el procesamiento manual de las imágenes [5]. Sin embargo, con vistas a una futura matriz energética en la que prevalecerá la participación de las FRE, y entre ellas, la energía solar, es perceptible que en los próximos años el país invierta en el crecimiento y la construcción de nuevo parques PV. En este contexto, sería evidente que la detección de puntos

calientes mediante el uso de las técnicas y los métodos actuales, demandaría un tiempo de realización aún más elevado. La demora se establecería no solo en la adquisición de las imágenes termográficas, sino también en el procesamiento de estas, llegando a prolongar la intensidad del deterioro del dispositivo. Al no poder detectarse oportunamente la aparición de puntos calientes, el daño podría extenderse al resto de módulos PV de la cadena e incluso afectar a otros componentes del sistema, incrementando con ello los costos de mantenimiento de estas instalaciones. Por esta razón, la presente investigación tiene como problema científico:

Problema científico:

Limitaciones en la detección de puntos calientes en los módulos fotovoltaicos instalados en Cuba que afectan su eficiencia, rendimiento y vida útil.

Objeto de investigación:

Los métodos de aprendizaje automáticos para la detección de puntos calientes en módulos fotovoltaicos.

Objetivo general:

Desarrollar un método automático para detectar puntos calientes en módulos fotovoltaicos, empleando técnicas de aprendizaje profundo.

Campo de la investigación:

Las técnicas basadas en el aprendizaje profundo para detectar de manera automática los puntos calientes en módulos fotovoltaicos.

Tareas de investigación:

1. Estudiar desde el punto de vista gnoseológico, histórico y actual las técnicas de detección de puntos calientes en módulos fotovoltaicos.
2. Revisar bases de datos reconocidas internacionalmente con imágenes representativas de puntos calientes en módulos fotovoltaicos.
3. Revisar arquitecturas de redes neuronales profundas existentes para la detección de puntos calientes en módulos fotovoltaicos.
4. Analizar las herramientas de *software* disponibles para el desarrollo de arquitecturas basadas en las redes neuronales profundas.

5. Implementar la arquitectura de red neuronal profunda seleccionada en imágenes reales obtenidas a partir de termografía infrarroja.

6. Evaluar los resultados obtenidos en correspondencia con el estado del arte estudiado.

Hipótesis de la investigación:

Si se desarrolla un método de detección automático basado en las técnicas de aprendizaje profundo a partir de imágenes termográficas, se podría identificar y predecir con mayor efectividad la aparición de puntos calientes en módulos fotovoltaicos, lo que elevaría su eficiencia, rendimiento y vida útil.

Métodos:

Los principales métodos empleados durante esta investigación se mencionan a continuación:

- Histórico-lógico en la revisión de bibliografía referente a los métodos de detección de puntos calientes en módulos fotovoltaicos a partir de termografía y la elaboración del marco teórico de la investigación.
- Hipotético-deductivo para establecer una arquitectura de red neuronal basada en las técnicas de aprendizaje profundo.
- Simulación para evaluar los resultados obtenidos.
- Experimental para el diseño de los experimentos y verificación de la hipótesis formulada.

Estructura de la tesis:

Esta tesis está estructurada en: Introducción, dos Capítulos, Conclusiones y Recomendaciones. El Capítulo 1 aborda el estudio del estado del arte de las técnicas empleadas en el mundo para la detección de puntos calientes en módulos fotovoltaicos y cómo el empleo de las arquitecturas de redes neuronales profundas son una tendencia en esta temática. El Capítulo 2 refiere la implementación de la arquitectura de red neuronal profunda seleccionada en imágenes reales obtenidas a partir de termografía infrarroja, así como la evaluación de los resultados obtenidos en correspondencia con el estado del arte estudiado. Finalmente, se exponen las Conclusiones y Recomendaciones derivadas del estudio, así como la bibliografía empleada y los anexos que fundamentan la obtención de los resultados alcanzados.

CAPÍTULO 1: Fundamentos teóricos de la detección de puntos calientes en módulos fotovoltaicos

Este capítulo tiene como objetivo, realizar un estudio del estado del arte de las técnicas existentes para la detección de puntos calientes en módulos fotovoltaicos. Primeramente, se caracterizan los elementos que permiten la obtención de la energía solar PV para la generación de electricidad. En este sentido, se explican los fallos de degradación más comunes que pueden presentarse en los módulos PV, haciendo énfasis en la aparición de puntos calientes y en los métodos y técnicas existentes para su detección. A partir de la revisión bibliográfica realizada, se demuestra el empleo de las técnicas de aprendizaje profundo como tendencia para detectar los efectos de degradación más severos en estos dispositivos, destacándose entre estas las arquitecturas de redes neuronales convolucionales. Por último, se especifican las limitaciones en las técnicas de detección de puntos calientes empleadas en Cuba y se resalta la necesidad e importancia de su realización de manera automática mediante el uso de técnicas de aprendizaje profundo.

1.1 Tecnología fotovoltaica

La energía solar fotovoltaica es la parte de la energía solar que transforma directamente el espectro visible de la radiación electromagnética en energía eléctrica a través del efecto PV. Este efecto se produce en materiales semiconductores, generando electricidad a partir de la radiación luminosa. El efecto PV se basa en otro efecto llamado “efecto fotoeléctrico”, el cual se produce cuando la luz o radiación electromagnética incide sobre un material provocando la emisión de electrones en su superficie [6].

1.1.1 Celdas fotovoltaicas

La unidad básica diseñada para la conversión de energía solar PV en electricidad es la célula o celda PV. Por lo general, su estructura consta de dos capas delgadas fabricadas de un material semiconductor puro (por lo general silicio) a las que se le

añaden de manera controlada cantidades diminutas de otros elementos químicos con diferentes concentraciones (usualmente boro y fósforo) para afectar sus propiedades eléctricas.

Los semiconductores están compuestos por dos tipos de portadores de corriente: unos con carga eléctrica negativa (N), constituidos por electrones libres, y otros con carga eléctrica de igual magnitud y signo contrario (P) denominados “huecos”. Al ser iluminada la celda, se induce un campo eléctrico permanente entre ambas capas que permite el movimiento de electrones en una única dirección, desde la capa tipo N (iluminada) hacia los huecos libres de la capa tipo P (no iluminada). La unión PN que se forma entre ellas, crea una diferencia de potencial que permite que el material semiconductor de las celdas se comporte como una unidad generadora de electricidad. La capa iluminada es sometida a un proceso de texturización, mediante el cual se le aplica un revestimiento antirreflectante para reducir la cantidad de radiación solar que se refleja en su superficie, luego se coloca sobre ella una rejilla metálica cuya función es recopilar la electricidad producida por la celda (Anexo 1). El silicio es el semiconductor más ampliamente usado para la fabricación de celdas PV. Según la pureza del material, estas se clasifican en tres tipologías: monocristalinas, policristalinas y de capa fina o “amorfa”, aunque esta última es la menos empleada. Cada una de estas celdas son capaces de producir corrientes entre 2-4 A, a una tensión de 0.46 - 0.48 V.

1.1.2 Módulos fotovoltaicos

Los módulos PV o paneles solares son dispositivos constituidos por una estructura de soporte sobre la cual son montadas y encapsuladas un conjunto de celdas fotovoltaicas. La mayoría de los módulos PV poseen entre 36 y 96 celdas interconectadas en serie (permitiendo aumentar la tensión de salida del módulo) y/o en paralelo (que permite aumentar la intensidad total), de modo que con estas conexiones se obtienen potencias y tensiones mucho más elevadas que las generadas individualmente.

Un módulo PV, de afuera hacia adentro, está conformado por:

- Marco de aluminio anodizado.

- Cubierta frontal, fabricada de vidrio templado de 3 - 4 mm de espesor para protegerlo de impactos o agentes atmosféricos.
- Encapsulante de las celdas, comúnmente etil-vinil-acetato (EVA), encargado de proteger las conexiones intracelulares de vibraciones e impactos.
- Celdas PV, conectadas al módulo por la capa N a través de cintas metálicas soldadas a sus rejillas e interconectadas entre ellas juntando las cintas de la capa N de una con la capa P de la siguiente.
- Capa de polivinilo fluoruro (PVF, comercialmente denominado TEDLAR) para aislar eléctricamente al módulo y protegerlo de la humedad.
- Caja de protecciones IP-65, hermética al polvo y protegida contra el agua, en su interior se encuentran los bornes de conexión positivo y negativo del módulo y los diodos de bloqueo y de paso (diodos *by-pass*). Para proteger a las personas de descargas eléctricas, las estructuras metálicas del equipo suelen estar conectadas a tierra.

La Figura 1 muestra los elementos que componen un módulo PV típico.



Figura 1. Estructura de un módulo PV. Fuente: [7].

Las características de cada módulo PV son especificadas en las llamadas hojas de datos. En estas se detalla la información que debe ser incluida obligatoriamente en la documentación del producto para asegurar su uso debido y seguro, de acuerdo con las normas de la Comisión Electrotécnica Internacional IEC, que establecen los requisitos para el mercado, la placa de características y la documentación de todo tipo de dispositivos. Algunos parámetros importantes de los módulos PV son:

- Corriente de cortocircuito (I_{sc}): Máxima corriente de salida del módulo fotovoltaico sin carga a una irradiancia y temperatura determinadas.

- Tensión en circuito abierto (V_{oc}): Máxima tensión de salida del módulo sin carga conectada, a una irradiancia y temperatura determinadas.
- Potencia eléctrica máxima (P_{max}): Máxima potencia que produce el panel. También se denomina potencia de pico.
- Corriente en el punto de máxima potencia (I_{mp}): Valor de la corriente para P_{max} .
- Tensión en el punto de máxima potencia (V_{mp}): Valor de tensión para la P_{max} .
- Factor de forma (FF): Valor correspondiente al cociente entre la P_{max} y el producto de I_{sc} por V_{oc} . Proporciona una idea de la calidad del dispositivo.
- Temperatura de operación nominal de la célula (TONC): Temperatura media de equilibrio de las células de un módulo en condiciones ambientales de referencia específicas. Se realiza a circuito abierto y el soporte debe tener orientación normal a la radiación solar incidente del mediodía.
- Coeficiente intensidad-temperatura (α): Variación de la I_{sc} del módulo por grado centígrado de variación de la temperatura de sus celdas. Se expresa en mA/°C.
- Coeficiente tensión-temperatura (β): Variación de la V_{oc} del módulo por grado centígrado de variación de la temperatura de sus celdas. Expresado en mV/°C.

1.1.3 Generadores fotovoltaicos

A la composición de un grupo de módulos PV, instalados en estructuras adecuadas y conectados en cadena (*string*) a otros equipos para acondicionar la tensión que entregan, se le denominan generadores PV. Los elementos que los componen varían en dependencia del tipo de instalación y su diseño. Por lo general cuentan con un sistema de acumulación de energía eléctrica (batería) al cual se acopla un regulador controlando los procesos de carga y descarga de esta, y un inversor de corriente continua a corriente alterna para suministrar debidamente la energía generada a los elementos receptores [8].

Los generadores PV de acuerdo a su tipo y aplicación se clasifican en:

- Generadores PV conectados a la red eléctrica (en inglés, *grid tie*): La energía generada (en corriente continua) se devuelve a la red eléctrica (en corriente alterna) a través de un inversor con la única misión de comercializar toda la energía producida. Comúnmente son denominados plantas generadoras PV.
- Generadores PV aislados de la red eléctrica (en inglés, *off grid*): La energía que generan los módulos (en corriente continua) se almacena en baterías, para posteriormente, a través de un inversor, suministrarla a las cargas en forma de corriente alterna.
- Generadores PV de autoconsumo: Son aquellas instalaciones conectadas a la red eléctrica que generan electricidad para consumo propio. Dentro de esta clasificación existen dos modalidades: los de autoconsumo sin excedentes y los de autoconsumo con excedentes (Anexo 2).

1.2 Fallos de degradación más comunes en módulos fotovoltaicos

El tiempo de vida útil promedio de los módulos PV puede variar en dependencia de su fabricante y el tipo de material que se emplee para su confección, pero por lo general, se estima que pueden tener de entre 25-30 años de funcionamiento. Al encontrarse ubicados en un espacio al aire libre en las instalaciones fotovoltaicas, están expuestos a condiciones ambientales adversas. Debido a ello, tienden a presentar ciertos índices de degradación que, de no ser corregidos a tiempo, pueden ocasionar pérdidas a la instalación.

El término “degradación” en módulos PV, se refiere a una serie de procesos que afectan la potencia de salida del módulo y el estado seguro de operación del dispositivo, reduciendo su eficiencia y rendimiento en el tiempo [9]. Entre los fallos de degradación más comunes pueden mencionarse los siguientes: aparición de microfracturas en las celdas y microgrietas en el vidrio proporcionando puntos de entrada de humedad y otros elementos corrosivos; delaminación en mayor o menor grado, causando separaciones en las capas del módulo debido a condiciones ambientales adversas; fallos de conexión que implican una sobrecarga de electricidad en el sistema y provocan daños en los componentes; puntos calientes que provocan el deterioro de los materiales encapsulantes, etc.

Un estudio realizado por [9], reporta las principales causas de degradación de cientos de módulos PV (con tecnología de silicio cristalino) de prueba que fueron instalados durante los últimos 10 años. En este estudio se concluyó que los puntos calientes resultaron ser los fallos de degradación más importantes, debido a su alta clasificación de gravedad (Figura 2).

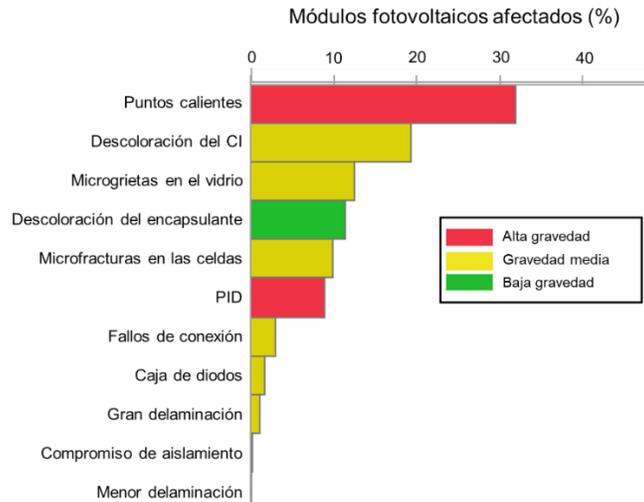


Figura 2. Fallos de degradación más significativos en módulos fotovoltaicos instalados en los últimos 10 años. Fuente: Adaptado de [9].

1.2.1 Puntos calientes en módulos fotovoltaicos

Un punto caliente, *hot spot* en idioma inglés, se define como una región localizada en una celda PV donde la temperatura es más elevada que en el resto, como consecuencia de una polarización inversa, debido a algún daño presente en el módulo [10]–[12]. La aparición de este modo de degradación en muchos de los casos puede ser originada, entre otras causas, por: sombras estacionales debido a objetos sobrepuestos al panel, fallo de interconexión o desajuste en las celdas, variaciones de temperatura, falta de mantenimiento y suciedad. Como resultado, la celda afectada se comporta como una carga que disipa la energía generada por el resto de celdas en forma de calor, lo que afecta seriamente la potencia de salida del módulo, ocasiona la pérdida de energía y provoca daños permanentes debido al deterioro de los materiales encapsulantes que la rodean (Figura 3 a). En casos

extremos, puede ocurrir la destrucción del módulo completo o incluso producirse un incendio, si no fueran detectados a tiempo (Figura 3 b).

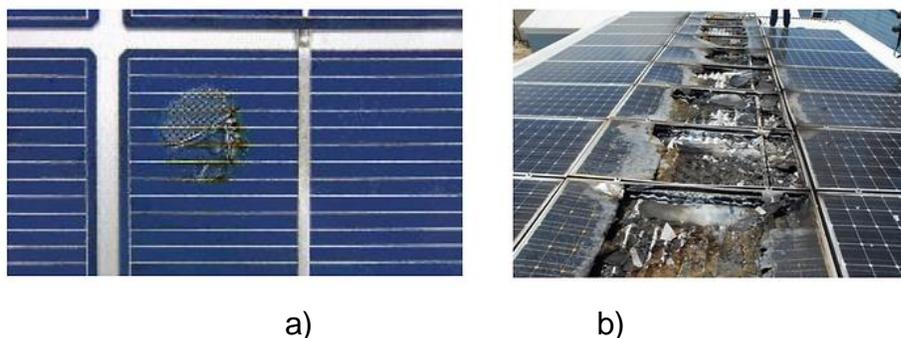


Figura 3. Efectos de los puntos calientes en módulos PV. a) a pequeña escala, b) a gran escala. Fuente: [13].

1.3 Técnicas y métodos de detección de puntos calientes en módulos fotovoltaicos

Diversos métodos han sido desarrollados para detectar y prevenir la aparición de puntos calientes en módulos PV, lo que ha ayudado a garantizar el óptimo funcionamiento de estos y a extender su vida útil. Estos se basan en técnicas que permiten la recopilación de los datos, las cuales pueden fundamentarse en la medición de los parámetros eléctricos que ofrece la curva de Corriente-Tensión (I-V) [12] o a partir de imágenes captadas con electroluminiscencia (EL) [14] o termografía infrarroja (termografía IR) [15]. A continuación, se explican brevemente en qué consisten cada una de estas técnicas:

- Curvas I-V: Consiste en realizar mediciones de tensión y corriente en una o varias celdas para obtener los parámetros de la curva característica I-V, compararlos con los datos nominales y determinar si el módulo respeta los parámetros de eficiencia declarados por el fabricante. Cuando un módulo PV presenta un punto caliente, la corriente de cortocircuito de la celda donde se encuentra es menor que la de otras, lo que provoca una incompatibilidad de energía entre sí y la curva I-V mostrará diferentes características según la distribución de este punto. Las curvas con puntos calientes se pueden dividir en tres tipos: el punto caliente con curva distorsionada,

el punto caliente con curva de un solo paso y la curva de doble paso [12], como se muestra en la Figura 4 a).

- Electroluminiscencia (EL): Desarrollada para detectar las recombinaciones radiativas de portadores de carga excitados bajo polarización directa [15] en una imagen que ha sido captada con una cámara de CCD (del inglés *Charge Coupled Device*). A pesar de ser una técnica no destructiva, precisa y capaz de cuantificar el origen de dicho modo de degradación, tiene como principal desventaja no poder realizarse cuando el panel sospechoso se encuentra en funcionamiento o solo efectuarse durante la noche en el mismo lugar de instalación [14]. En la Figura 4 b) se ha resaltado en un cuadro amarillo la celda de un módulo fotovoltaico con presencia de punto caliente, el cual fue detectado durante una prueba realizada con esta técnica.

- Termografía infrarroja (IR): Permite definir el comportamiento térmico de los cuerpos de acuerdo con la energía térmica que emiten. La detección se realiza de forma remota y sin contacto, proporcionando una imagen en tiempo real que es captada por medio de cámaras infrarrojas. Los puntos calientes detectados con esta técnica tienen una forma geométrica bien definida y distinguible. De acuerdo a un estudio realizado por [16], esta herramienta ha demostrado ser fiable y precisa para diagnosticar defectos de degradación, tanto ópticos como eléctricos, en celdas fotovoltaicas y, además identificar la ubicación precisa y la gravedad de los puntos calientes. La Figura 4 c) muestra la imagen IR de una celda fotovoltaica a la cual se le ha detectado un punto caliente.

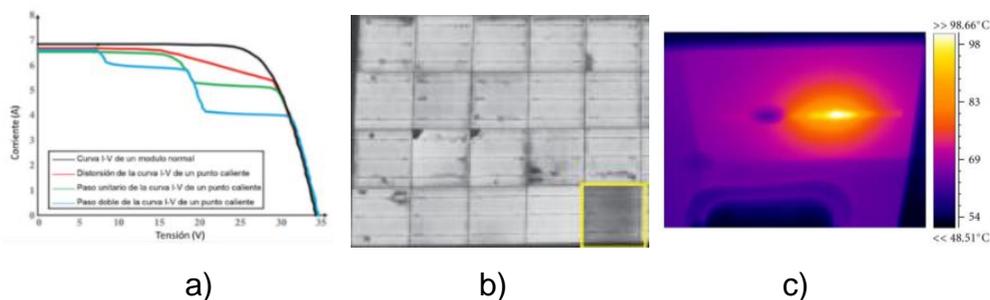


Figura 4. Técnicas más comunes de detección realizadas a módulos fotovoltaicos con puntos calientes. a) Curva característica I-V [12], b) Prueba de electroluminiscencia [12], c) Termografía infrarroja [16].

En términos generales, los métodos que se emplean a partir de las técnicas mencionadas anteriormente, pueden clasificarse en dos tipos: inspección visual y análisis automático [4]. Los de inspección visual consisten en el análisis, observación y/o comparación de los datos característicos con el fin de detectar fallos. Los de análisis automático, van más allá de la simple detección visual del daño e incorporan diversas técnicas de aprendizaje automático.

1.4 Aprendizaje automático y aprendizaje profundo

El aprendizaje automático (ML, del inglés *Machine Learning*) es una de las ramas de la inteligencia artificial (AI, del inglés *Artificial Intelligence*) más utilizadas a nivel internacional debido a las múltiples fortalezas y técnicas estadísticas que utiliza con fines predictivos. Mitchell en [17] define el concepto de ML como un programa de computadora que aprende de una experiencia E con respecto a alguna clase de tarea T y medida de desempeño P, cuando su desempeño en las tareas en T, medido por P, mejora con la experiencia E.

El ML propone un modelado analítico y automático de datos con reglas de partida a las que el algoritmo de aprendizaje se adapta para mejorar la tasa de acierto del modelo generado [18]. Puede emplear diferentes métodos de aprendizaje, dentro de los más comunes se encuentran: los de aprendizaje reforzado, los de aprendizaje supervisado y no supervisado, y los de aprendizaje profundo. El aprendizaje reforzado resuelve tareas mediante la técnica de ensayo y error y no utiliza conjuntos de datos para hacer determinaciones, sino la información recopilada del entorno al que está expuesto. El aprendizaje supervisado trabaja con conjuntos de datos previamente etiquetados y comprueba si, sobre conjuntos no conocidos, las predicciones son correctas al compararlas con su categoría o clase real. Por otro lado, el aprendizaje no supervisado entrena con datos que no contienen etiquetas ni información, y procede al ordenamiento y clasificación de estos en función de los patrones que reconoce por sí mismo, de acuerdo a similitudes o secuencias encontradas.

El aprendizaje profundo (DL, del inglés *Deep Learning*) constituye uno de los métodos de ML más destacados. Como ventaja se reconoce el manejo de datos a

gran escala y la extracción automática de características efectivas, a partir de datos sin preprocesar o con un mínimo de preprocesamiento [19]. El DL se basa en redes de algoritmos inspiradas en la estructura del cerebro, conocidas como redes neuronales profundas (DNN, del inglés *Deep Neural Network*).

Existen diversas arquitecturas de DNN [20], las que se basan en un aprendizaje supervisado como las redes neuronales convolucionales (CNN, del inglés *Convolutional Neural Network*), las redes neuronales recurrentes (RNN, del inglés *Recurrent Neural Network*), las de memoria a corto y largo plazo (LSTM, del inglés *Long/Short Term Memory*), y las basadas en aprendizaje no supervisado como las redes profundas de creencias (DBN, del inglés *Deep Belief Network*) y los autocodificadores (AE, del inglés *Auto Encoder*). Esta variedad de arquitecturas se debe, en gran parte, a las nuevas capacidades de hardware con disponibilidad de unidades de procesamiento gráfico (GPU, del inglés *Graphics Processor Unit*) y a la aparición de nuevas técnicas para el entrenamiento de los modelos.

1.5 Las redes neuronales artificiales y las redes neuronales profundas

Una red neuronal artificial (ANN, del inglés *Artificial Neural Network*) se define como un sistema inspirado en el sistema nervioso humano, estableciendo una relación entre sus entradas y salidas por medio de modelos matemáticos simples que permiten procesar la información. Las neuronas son la unidad básica de procesamiento de información de una ANN y, en una red, se encuentran interconectadas en paralelo y organizadas en una estructura que emplea tres tipos de capas simples: la de entrada, la capa oculta y la capa de salida [21]. La Figura 5 a continuación muestra la estructura de una red neuronal con sus capas de entrada, ocultas y de salida.

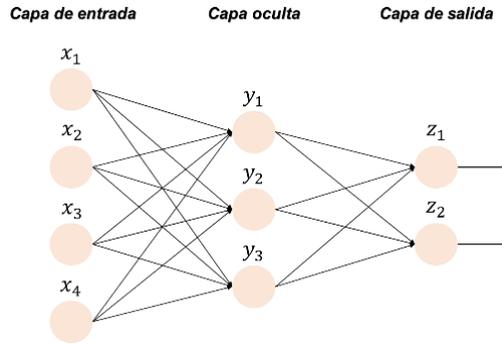


Figura 5. Estructura de una red neuronal artificial. Fuente: Autora.

El modelo computacional de una neurona se muestra en la Figura 6. En esencia, la neurona calcula la suma ponderada de sus entradas x_i a través de los pesos sinápticos w_i , añadiendo un sesgo b y una función de activación f [19]:

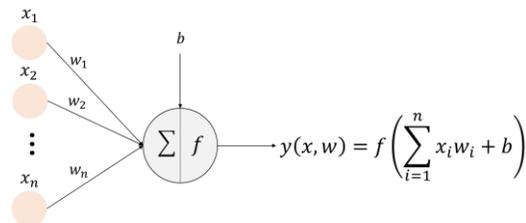


Figura 6. Modelo computacional de una neurona. Fuente: Autora.

En las ANN, los pesos sinápticos (*weights*) son coeficientes que determinan la intensidad de la señal de cada entrada registrada a la red y sus valores se modifican durante el entrenamiento. El sesgo (*bias*) es un componente adicional de cada nodo de la capa oculta y de la capa de salida cuya función principal es desplazar el resultado obtenido a través de la función de activación. Esta función, conocida también como función de transferencia o función de umbral (*threshold*), realiza una transformación matemática para aportar un comportamiento no lineal, de forma tal que el modelo pueda resolver problemas más complejos [22]. Existe una amplia variedad de funciones de activación para las ANN. Las más populares son la función sigmoide, la tangente hiperbólica, ReLU, Leaky ReLU y Softmax [23], las que se muestran en la Tabla 1.

Tabla 1. Algunas funciones de activación de una ANN.

Nombre	Función	Salida	Característica
Sigmoide	$y = \frac{1}{1 + e^{-z}}$	(0,1)	- Para problemas de clasificación binaria. - No es simétrica respecto a cero
Tangente hiperbólica	$y = \tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	(-1,1)	- Simétrica alrededor del origen
ReLU	$y = \begin{cases} 0, & z < 0 \\ z, & z \geq 0 \end{cases}$	[0, ∞)	- Es la más empleada en capas ocultas debido a que su derivada es 1.
Leaky ReLU	$y = \begin{cases} \alpha \cdot (e^{-z} - 1), & z < 0 \\ z, & z \geq 0 \end{cases}$	(-∞, ∞)	- Extensión de Relu que define los valores negativos de x como una componente lineal extremadamente pequeña.
Softmax	$\hat{y}_i = \frac{e^{y_i}}{\sum_{j=1}^n e^{y_j}}$ con n=número de neuronas de la capa de salida	$\sum_{i=1}^n \text{salidas} = 1$	- Para problemas de clasificación multiclase, comúnmente empleada en la última capa.

Las DNN son una subcategoría dentro de las ANN. A diferencia de estas, las arquitecturas de estas redes emplean más de una capa oculta, de ahí el término “profundo”.

1.5.1 Aprendizaje de las redes neuronales profundas

El proceso de aprendizaje de las DNN propicia que la red adquiriera conocimiento a través de experiencias. Estas redes a su vez pueden presentar dos modos de aprendizaje: supervisado y no supervisado. Este epígrafe se centrará en los del primer tipo.

El objetivo principal del aprendizaje supervisado de las DNN consiste en encontrar una regla de modificación de sus pesos en respuesta a la información de entrada.

Se determina que una red neuronal ha aprendido cuando los valores de los pesos de las conexiones neuronales durante el entrenamiento permanecen estables [21]. Comúnmente, estos valores sinápticos se inicializan de manera aleatoria siguiendo una distribución de probabilidad conocida [19] y su proceso de aprendizaje implica la actualización de estos parámetros. El algoritmo o regla de referencia que se emplea para el aprendizaje es la retropropagación del error (BP, del inglés *Back-Propagation*) [24].

El procedimiento BP consiste en ajustar iterativamente los pesos de las conexiones en la red de forma tal que se minimice la diferencia entre el valor actual y el deseado. Este proceso permite que las predicciones del modelo se aproximen a las clases predefinidas del conjunto de entrenamiento. La actualización de los pesos en cada neurona se realiza hasta que la red converja hacia un estado que permita clasificar correctamente los patrones presentados. La tasa de aprendizaje α es el parámetro que determina la velocidad con que cambian los pesos de la red y tiene un rango de 0 a 1 [25].

La función responsable de medir la diferencia o similitud entre el valor de salida esperado y el real, es conocida como función de costo o función de pérdida [26] y esta puede variar según el tipo de tarea a resolver. De acuerdo con [19], las dos funciones de costo más empleadas para las DNN son:

- 1- Error medio cuadrático (*Medium Square Error*, MSE): Comúnmente empleado en tareas de regresión. Calcula el valor medio de la diferencia al cuadrado entre los vectores de salida \hat{y} y el deseado y , siendo n = cada una de las muestras:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

- 2- Entropía cruzada categórica (*Categorical cross-entropy*, CCE): Ampliamente utilizada en tareas de clasificación. Recibe como entrada la salida de la función *Softmax* $\hat{y} = [\hat{y}_1, \hat{y}_2, \dots, \hat{y}_n]$ y el esperado $y = [y_1, y_2, \dots, y_n]$, con n = número de clases.

$$H(\hat{y}, y) = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i)$$

Para hallar el mínimo de la función de costo y con ello los valores óptimos de los pesos sinápticos, generalmente se emplea un método de búsqueda denominado descenso del gradiente (GD, del inglés *Gradient Descent*). Este método busca reducir iterativamente el error de predicción del modelo de aprendizaje indicando la dirección y magnitud del cambio que debe aplicarse a los pesos [24]. El GD constituye la base de otros optimizadores como SGD (del inglés *Stochastic Gradient Descent*), RMSprop, Adam, Adagrad, entre otros [19].

1.6 Redes neuronales convolucionales

Las redes neuronales convolucionales (CNN) son un tipo de DNN inspirada en la estructura del sistema visual humano, específicamente en la biología de las neuronas y sus conexiones. Su propósito es extraer las características más relevantes de determinada imagen a su entrada [27].

La convolución es el bloque principal de construcción de una CNN y su término se refiere a la combinación matemática de dos funciones o conjuntos de información. Este procedimiento consiste en filtrar matrices recorriendo la imagen a clasificar [28]. Las arquitecturas de una CNN generalmente incluyen 3 tipos de capas: capas convolucionales en la entrada, capas de agrupación (*pooling*) y capas de clasificación a la salida. A continuación, se describe el funcionamiento de estas capas:

- Capas de convolución: Identifican las características de la imagen de entrada mediante operaciones convolucionales en el dominio discreto. La convolución de la matriz de entrada se realiza utilizando una matriz convolucional, llamada núcleo (*kernel*), aplicada con un paso de aplicación específico, la cual devuelve una matriz, llamada mapa de activación, que contiene las características extraídas de esta región de la imagen. Luego se le agrega un sesgo y se utiliza una función de activación como en las ANN [19]. El tamaño de la salida de la capa se controla empleando tres hiperparámetros: profundidad (número de filtros aplicados), paso (número de elementos que se deslizan al aplicar el filtro) y relleno (*padding*) para preservar o no el tamaño de la entrada (Figura 7).

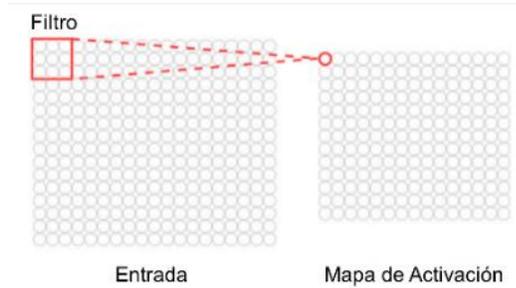


Figura 7. Capa convolucional de una CNN. Fuente: Adaptado de [29]

- Capas de reducción: Se sitúan a la salida de las capas convolucionales y se emplean para reducir progresivamente la cantidad de parámetros y cálculos en la red. Para resaltar características específicas de la imagen en esta capa se emplean operaciones de agrupación con el fin de determinar el tamaño del área sobre la que se desea aplicar el submuestreo. Estas capas pueden ser de varios tipos: submuestreo por valor máximo (*max-pooling*) la cual permite extraer el valor máximo, submuestreo por valor mínimo (*min-pooling*) empleada para extraer el valor mínimo, y submuestreo por valor promedio (*average-pooling*) la cual determina el valor medio del grupo de neuronas seleccionadas [19]. La incorporación de capas de reducción ayuda a evitar el sobreajuste de la red (Figura 8).

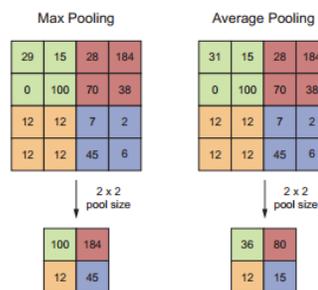


Figura 8. Capa de reducción con submuestreo máximo y promedio. Fuente: [18]

- Capas de clasificación: Ubicadas en la etapa final del análisis de los datos. Para procesar la información de las capas convolucionales y de agrupación previas, se aplica una función de aplanamiento (*flatten*) que transforma el mapa de activación resultante en un vector unidimensional, el cual constituye su elemento de entrada. Generalmente las capas de clasificación se

componen de una o varias capas totalmente conectadas (FC, del inglés *fully-connected*), también conocidas como capas densas, seguidas de una capa de activación, y en conjunto, contribuyen a obtener las predicciones de salida del modelo.

1.6.1 Ejemplos de arquitecturas de redes neuronales convolucionales

Las diversas arquitecturas de CNN existentes admiten una inmensa variedad de combinaciones de capas. Gracias a la influencia que tienen en la capacidad de aprendizaje, generalización y procesamiento de grandes cantidades de datos, permiten que sean aplicables a todo tipo de imágenes. A continuación, se describen algunas de las características generales de las arquitecturas más mencionadas en la literatura consultada.

- Arquitectura *Alex Net*

Fue propuesta por Alex Krizhevsky [30] en 2012 y con ella se logró una capacidad de generalización superior, compensaciones adecuadas entre velocidad y precisión, un tiempo de entrenamiento rápido y una alta estabilidad. Estudios como los de [31], [32] y [33] reflejaron que esta arquitectura aporta altos valores de exactitud y precisión alcanzando resultados por encima del 90%. El modelo *AlexNet* incluye ocho capas: cinco convolucionales y tres capas FC y emplea la función de activación ReLU. El artículo original implementa la arquitectura dividiéndola en dos partes para ser entrenada en 2 GPU simultáneamente. En la Figura 9 se muestra la estructura de la arquitectura *AlexNet*.

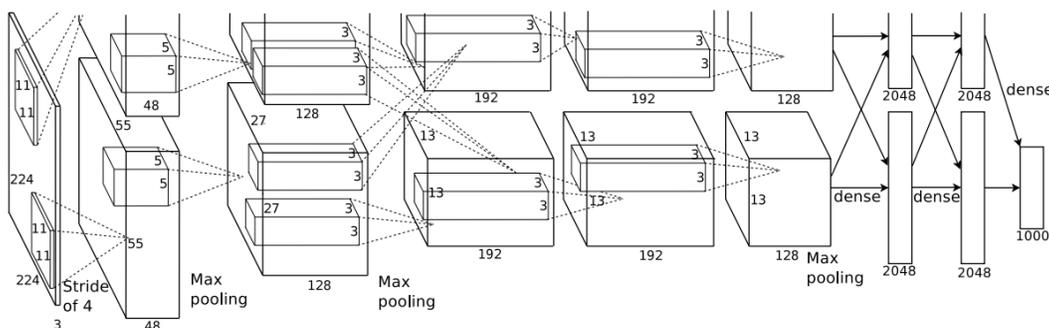


Figura 9. Arquitectura *AlexNet*. Fuente: [30].

- Arquitectura *ResNet* (*Residual Net*)

Fue desarrollada en 2015 por He, et al. [34], los que reformularon explícitamente las capas convolucionales de las CNN como funciones residuales de aprendizaje con referencia a las entradas de la capa anterior, en lugar de aprender funciones sin referencia. Estas capas residuales están dotadas de conexiones de atajo o capas identidad, que permiten los pasos a las siguientes de manera directa, mejorando considerablemente el entrenamiento del modelo [33]. La arquitectura *ResNet* puede presentar variantes como *ResNet-34*, *ResNet-50*, *ResNet-101*, *ResNet-152*, *ResNeXt* y *ResNet-D*. En la Figura 10 se muestra un bloque tradicional de esta arquitectura.

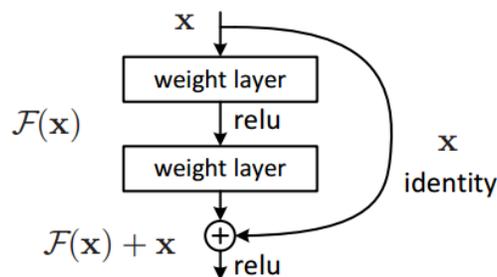
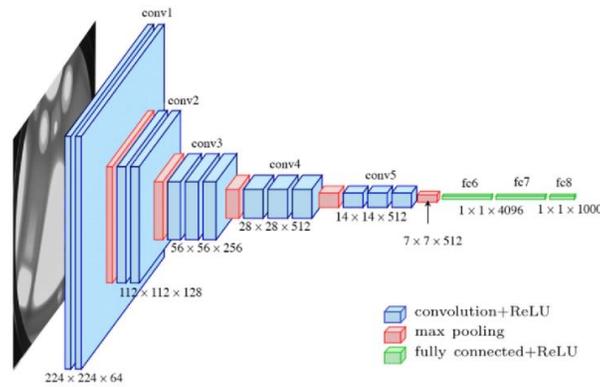


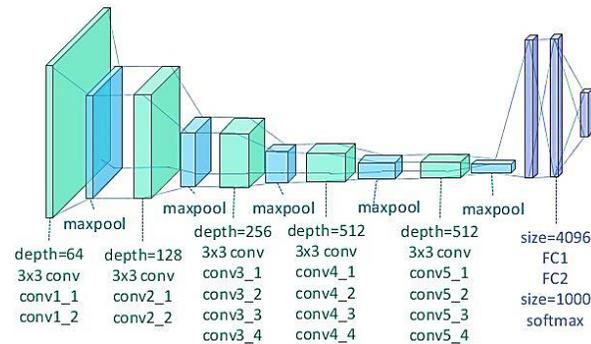
Figura 10. Bloque tradicional de la arquitectura *ResNet*. Fuente: [34].

- Arquitectura *VGG*

Fue propuesta por Simonyan y Zisserman [35] y adquirió notoriedad al ganar el primer y segundo lugar en las categorías de localización y clasificación respectivamente en el Desafío de Reconocimiento Visual a Gran Escala de *ImageNet* (ILSVRC) en 2014. La arquitectura *VGG* tiene seis estructuras principales, cada una de las cuales se compone principalmente de múltiples capas convolucionales y capas completamente conectadas. Entre las variantes *VGG* podemos encontrar *VGG-16* [36] (Figura 11 a) y *VGG-19* [37] (Figura 11 b).



a)



b)

Figura 11. Arquitecturas VGG. a) Modelo VGG-16. b) Modelo VGG-19. Fuente: [33].

- Arquitectura *MobileNet-v2*

Fue propuesta en un trabajo realizado por Sandler et al. [38] en 2018 como una arquitectura de red muy simple que permitió construir una familia de modelos móviles altamente eficientes. Esta arquitectura se basa en el uso de capas convoluciones separables en profundidad y emplea una estructura residual invertida. La entrada y salida del bloque residual son capas delgadas de cuello de botella opuestas a los modelos residuales tradicionales que utilizan representaciones expandidas en la entrada [33]. En la Figura 12 se muestra la diferencia entre las conexiones de los bloques residuales clásicos con una gran cantidad de canales y las conexiones de cuellos de botella de los bloques invertidos.

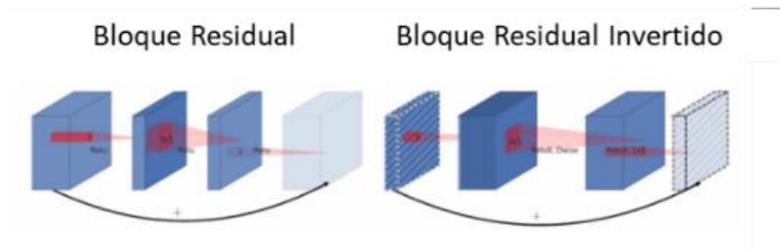


Figura 12. Diferencia entre los bloques residuales y los bloques residuales invertidos de la arquitectura *MobileNet-v2*. Fuente: Adaptado de [38].

1.6.2 Técnicas de regularización

El sobreajuste (*overfitting* en idioma inglés), constituye uno de los desafíos más comunes durante la etapa de entrenamiento de las redes neuronales. Se produce cuando el modelo de red neuronal memoriza los datos de entrenamiento en lugar de aprender patrones generales que puedan aplicarse a los nuevos, dificultando su capacidad de generalización ante datos desconocidos. Las causas más frecuentes de sobreajuste ocurren cuando el modelo cuenta con demasiadas capas, con gran número de parámetros o si se ha seleccionado un conjunto de entrenamiento pequeño, lo que provoca que el modelo se ajuste demasiado bien a los datos de entrenamiento y sea más propenso a memorizar patrones.

Existen diferentes técnicas que permiten evitar o mitigar el sobreajuste en las redes neuronales profundas. La elección de estas dependerá del problema específico y de los datos disponibles. Para obtener un mejor rendimiento en la generalización del modelo se pueden combinar múltiples técnicas. Algunas de las más empleadas se describen brevemente a continuación:

1. Aumento de datos (en inglés *data augmentation*):

Consiste en generar nuevas muestras de entrenamiento aplicando diversas transformaciones sobre los datos originales, preservando la etiqueta. En el caso de imágenes, las transformaciones pueden ser geométricas, incluyendo rotaciones y traslaciones en una o dos direcciones; ajustes de iluminación y contraste, escalado, etc. (Figura 13).

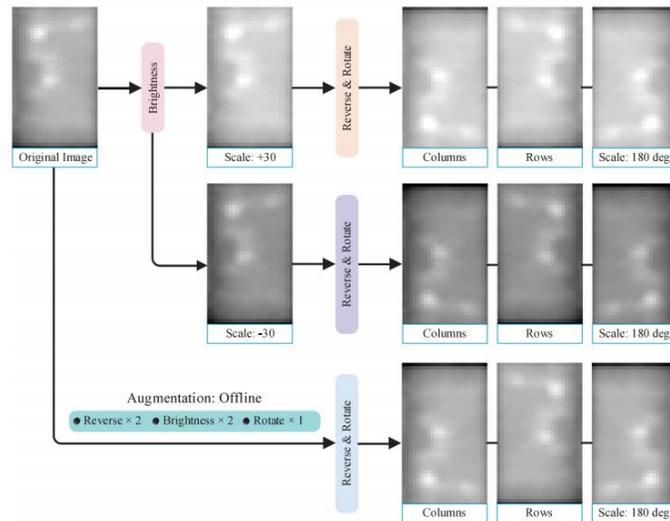


Figura 13. Algunas transformaciones en imágenes aplicando la técnica de aumento de datos. Fuente: [39].

2. Reducción del tamaño del modelo:

El número de parámetros del modelo se reduce eliminando una cantidad determinada de capas o neuronas. No existe una fórmula exacta para realizar una reducción óptima de las capas, por lo que se recomienda que durante el entrenamiento del modelo sean evaluadas diversas arquitecturas, tratando de mantener siempre su expresividad. Esto se logra seleccionando en un principio pocos parámetros y capas, para luego incrementar de manera gradual el tamaño y el número de estos.

3. Capas de normalización en lotes (BN, del inglés *batch normalization*):

Se basa en incorporar un paso adicional, habitualmente entre las neuronas y la función de activación con el objetivo de normalizar las activaciones de salida [40]. Por lo general, esta técnica se realiza empleando dos parámetros por activación: la media y la varianza del conjunto de entrenamiento. Como es común emplear en el entrenamiento el método de optimización SGD, estos parámetros son aplicados en cada lote (*batch*) de la entrada, lo que garantiza una aceleración durante el entrenamiento [19].

4. Capas de dropout.

La técnica de *dropout* consiste en desactivar aleatoriamente un número exponencial de neuronas y sus conexiones en cada propagación hacia adelante. Su principal objetivo es evitar la dependencia excesiva de ciertas neuronas y fomentar la contribución equitativa de todas estas en la predicción final del modelo [41]. Al ser aplicada, estas capas reciben el nombre de "adelgazadas" y en ellas una variable aleatoria en cada función de activación representa las desactivaciones neuronales siguiendo una distribución de Bernoulli de probabilidad p [19]. En la Figura 14 se representa la aplicación de esta técnica sobre 2 capas ocultas en una red neuronal.

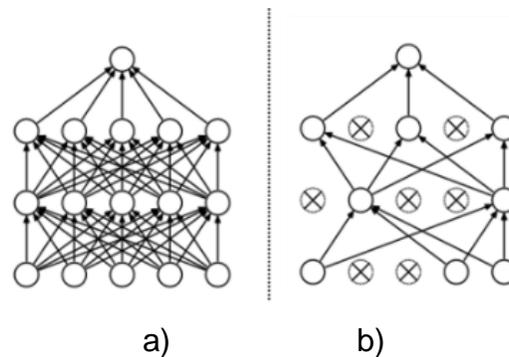


Figura 14. Modelo de red neuronal con 2 capas ocultas: a) sin *dropout*, b) adelgazada con *dropout*. Fuente: Adaptado de [41].

5. Regularización y restricción de pesos:

Consiste en penalizar los coeficientes grandes en la función de costo con el fin de fomentar a la red a emplear pesos más pequeños, restringiéndolos por debajo de un umbral predefinido. Existen dos tipos de regularización: L1 y L2. La regularización L1 consigue convertir la matriz de pesos en una matriz cuyos elementos son en su mayoría muy cercanos a cero, contrariamente a la regularización L2. Mientras más pequeños sean estos pesos, el modelo será más estable y menos propenso a presentar sobreajuste [42].

6. Decaimiento de la tasa de aprendizaje (LR, del inglés *learning rate*):

Determina la amplitud del paso en cada iteración del entrenamiento para ajustar los pesos de las neuronas hacia el mínimo global de la función de costo. Al variar gradualmente, por lo general de mayor a menor, los valores de la tasa de aprendizaje en el transcurso del entrenamiento, el modelo logra una convergencia

más rápida. Esto se logra supervisando diferentes monitores sobre el conjunto de validación, los cuales pueden ser los valores de pérdida (*val_loss*) o exactitud (*val_accuracy*) y de paciencia, en la cual se establece la cantidad de épocas a esperar sin que ocurran mejoras en el valor supervisado [19]. A partir de esta última se reducirá la tasa de aprendizaje.

7. Parada temprana del entrenamiento (ES, del inglés *early stopping*):

La idea de esta técnica es monitorear el desempeño del modelo sobre el conjunto de validación y, basado en su comportamiento, detener el entrenamiento cuando se detecta el sobreajuste. Después de este punto, la capacidad de generalización del modelo puede empeorar. Los monitores que emplea esta técnica son los mismos de la técnica de decaimiento de la tasa de aprendizaje [43].

1.7 Empleo de métodos automáticos en la detección de puntos calientes

El auge en el empleo de la energía solar fotovoltaica en la actualidad justifica la necesidad de optimizar la eficiencia, mantener las características de rendimiento, la confiabilidad y el tiempo de vida útil de las plantas generadoras PV. Debido a que los módulos PV se encuentran expuestos a múltiples factores que pueden acelerar sus índices de degradación. Diversos estudios han implementado técnicas de ML para realizar inspecciones y detectar fallas de manera automática en estos dispositivos. A continuación, se resumen los resultados de algunas investigaciones realizadas en los últimos años, referidas al empleo de métodos automáticos para detectar puntos calientes en módulos PV, así como los tipos de arquitecturas empleadas, las técnicas y las bases de datos utilizadas, la exactitud y precisión alcanzada (Tabla 2).

Tabla 2. Métodos basados en ML que han sido empleados para detectar puntos calientes.

Año, Ref.	Método	Técnica	Base de Datos	Exactitud	Precisión
2023, [44]	CNN + JSEG	Termografía	Privada	99.5%	-

2023, [45]	KNN (modelo fino)	Curva I-V	“GPVS-Faults”	-	99.2%.
	DT			-	99.2%.
2022, [32]	CNN (AlexNet)	Termografía	“InfraredSolarModules”	98.65%	97.37%
	CNN (ShuffleNet)			97.30%	96.05%
	CNN (SqueezeNet)			95.27%	93.51%
	CNN (ResNet-50)			94.59%	94.59%
	CNN (GoogLeNet)			95.95%	95.95%
	CNN (MobileNet-v2)			97.30%	98.61%
2022, [39]	Multi-scaled CNN (AlexNet)	Termografía	“InfraredSolarModules”	99.52%	97.20%
2022, [46]	SVM	Termografía	12 módulos PV modelo	-	97%
	FLC	Curva I-V	<i>SoliTek G/G 245W</i>	-	98%
2022, [11]	KNN + rgSIFT	Termografía	375 muestras	-	98.7%
2021, [47]	FCN (U-Net)	Termografía	“Photovoltaic System Thermal Images” + “InfraredSolarModules”	-	92.95%
	+ CNN (AlexNet)			-	97.32%
2021, [48]	Faster R-CNN	EL	“ELPV” + “TecnaliaPR”	-	99.36%
	+ CNN (EfficientNet-B1)			84.0%	-
	+ AE			99.2%	-
2020, [49]	RCN	Termografía	800 imágenes tomadas a un parque PV	99.02%	91.67%

La tabla de referencia, evidencia la tendencia al empleo de métodos basados en el aprendizaje profundo a partir de la termografía infrarroja para la detección de puntos calientes en módulos PV. Puede observarse que las CNN basadas en la arquitectura *AlexNet* empleando la base de datos *InfraredSolarModules* han sido las más empleadas en la detección de este tipo de anomalías.

1.8 Detección de puntos calientes en módulos fotovoltaicos en Cuba

La ubicación geográfica de Cuba presenta un potencial relativamente alto y estable de radiación solar en toda su extensión. Teniendo en cuenta este factor tan importante, desde el año 2014 el país ha fomentado la incorporación de las FRE en la matriz energética nacional. Lo anterior se refrenda en diferentes instrumentos jurídicos y en las políticas públicas a favor del uso eficiente de la energía [50] como son: el Decreto Ley No. 345 [51] y la estrategia gubernamental que da cumplimiento al séptimo de los Objetivos de Desarrollo Sostenible [52], garantizando así el acceso a una energía asequible, fiable, sostenible y moderna para todos.

Diversos estudios [2], [53], [54] han mostrado que la energía solar fotovoltaica es la FRE que mejores resultados ha presentado en el país y desde 2019, representa la segunda con mayor participación en la matriz eléctrica nacional. Según reporta el Ministerio de Energías y Minas [3], Cuba cuenta con un total de 72 parques construidos, con 227 MW (Megawatts) de potencia, que alcanzan una generación eléctrica de 310 GWh (Gigawatts hora) anuales y sustituyen aproximadamente 81 mil toneladas de combustible al año (Figura 15).

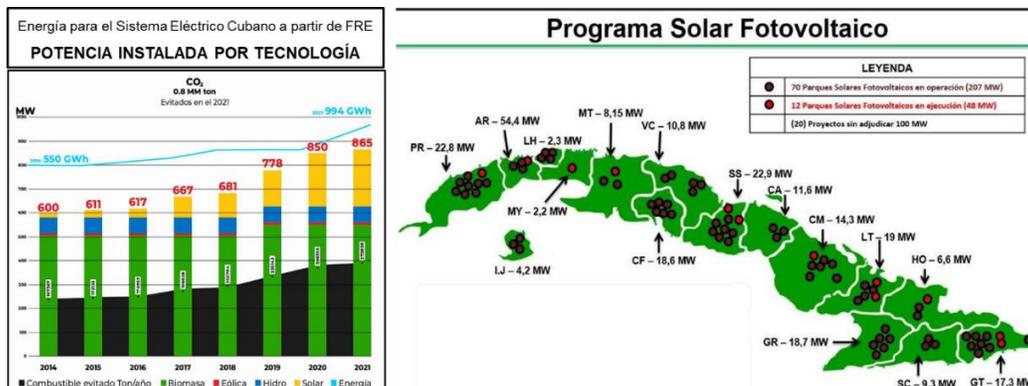


Figura 15. Tecnología fotovoltaica en Cuba. Fuente: [3].

La tecnología fotovoltaica en Cuba enfrenta los mismos problemas de degradación que pueden encontrarse en otras latitudes, siendo los puntos calientes las averías más frecuentes en módulos fotovoltaicos. Por lo general, la detección de estos se realiza empleando técnicas tradicionales de inspección visual a partir de termografía infrarroja como se refiere en [5]. Sin embargo, la revisión bibliográfica efectuada permite comprobar que el empleo de métodos automáticos constituye una herramienta mucho más eficaz y rigurosa, recalcando su amplia aceptación internacional.

En el país resultan insuficientes las experiencias documentadas en este sentido y los casos de estudio no refieren generalización de soluciones para prevenir y detectar de forma automática defectos de degradación como estos. Sumado a lo anterior, existen limitaciones tecnológicas que inciden en la aplicación de técnicas y métodos más atemperados al desarrollo tecnológico que exhiben otras naciones con condiciones climatológicas similares [47],[10],[55],[56].

Conclusiones parciales

El estudio realizado permite arribar a las siguientes conclusiones:

1. Los puntos calientes constituyen uno de los defectos de degradación más frecuentes y severos en módulos fotovoltaicos.
2. La detección de puntos calientes en módulos fotovoltaicos se realiza generalmente empleando métodos automáticos, siendo la combinación de redes neuronales profundas con termografía infrarroja las que predominan en la revisión bibliográfica.
3. En Cuba, resultan insuficientes y escasamente documentados los estudios que emplean métodos automáticos para la detección de estas anomalías, lo que abre un nicho de investigación promisorio que tributa a la soberanía tecnológica.

CAPITULO 2. Arquitectura de red neuronal profunda para detectar puntos calientes en módulos fotovoltaicos

La tendencia internacional en el empleo de métodos automáticos para la detección de puntos calientes en módulos PV, con énfasis en las redes neuronales profundas, justifican en este trabajo la propuesta de una arquitectura de red neuronal convolucional para procesar imágenes de puntos calientes obtenidas mediante termografía infrarroja. En este capítulo se detalla el conjunto de pasos que integran el procedimiento propuesto para la predicción de puntos calientes en imágenes reales, el diseño de los experimentos realizados y los resultados más importantes obtenidos empleando herramientas de cómputo actuales y competitivas.

2.1 Propuesta de un método de detección automática de puntos calientes en módulos PV

El algoritmo propuesto en el presente trabajo se resume en la Figura 16. Su procedimiento parte de la adquisición de un conjunto de imágenes termográficas de módulos PV con diferentes anomalías, tomadas de la base de datos internacional “*InfraredSolarModules*”. A continuación, se procede a realizar el preprocesamiento de estas imágenes que implica aplicar la técnica de aumento de datos con el objetivo de incrementar la capacidad de generalización del modelo de red neuronal convolucional que será empleado.

El modelo utiliza como elemento de entrada dichas imágenes y emplea una estructura de CNN basada en la arquitectura *AlexNet*. Para su entrenamiento, se realizó un conjunto de experimentos que permiten evaluar a partir de un análisis de diferentes métricas, las predicciones realizadas por la red sobre un subconjunto de imágenes desconocidas. La solución se desarrolla en la aplicación web de código abierto *Google Colaboratory* empleando el lenguaje de programación Python en la versión 3.7.16. El procedimiento de la propuesta se muestra a continuación (Figura 16).

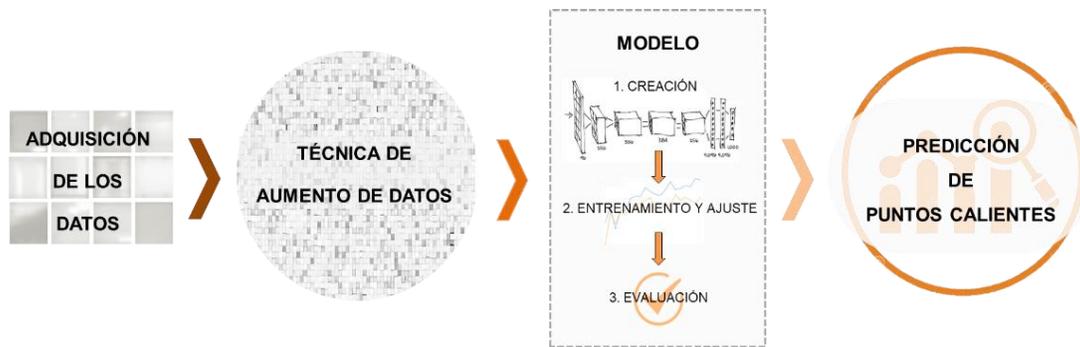


Figura 16. Esquema general de la solución propuesta. Fuente: Autora.

2.2 Adquisición de los datos de entrada.

El primer paso para el diseño del modelo de CNN propuesto en este trabajo consiste en la adquisición de datos, en este caso, imágenes. Para ello se consideraron, de las bases de datos (BD) referenciadas en las investigaciones analizadas en el estudio del estado del arte del anterior capítulo, las obtenidas mediante termografía. Las BD disponibles públicamente y correspondientes a esta descripción fueron 2: “*InfraredSolarModules*” y “*Photovoltaic System Thermal Images*”. Dado que, al realizar un análisis exploratorio de estas, se encontró que la primera contenía un total de 20,000 imágenes y la segunda solo 277, se escogió a “*InfraredSolarModules*” como la BD a emplear para entrenar el modelo.

2.2.1 Base de datos *InfraredSolarModules*

En [57], se presenta la BD internacional de dominio público “*InfraredSolarModules*”, la cual se encuentra disponible en [58] desde el año 2020. Esta contiene 20.000 imágenes infrarrojas en escala de grises tomadas por el grupo *Raptor Maps Inc.* Cada imagen tiene un tamaño 24×40 píxeles, con una resolución variable de entre 3.0 y 15.0 cm/píxel y representa diferentes anomalías encontradas en varios parques PV. Las imágenes se encuentran categorizadas en 12 clases: 11 de ellas referidas a defectos de degradación y la clase restante, sin anomalías. Las clases que refieren módulos defectuosos se encuentran definidas por los nombres: “Celda”, “Celda Múltiple”, “Agrietado”, “Punto Caliente”, “Punto Caliente Múltiple”, “Falla del Diodo”, “Falla Múltiple del Diodo”, “Desconectado”, “Sombreado”,

“Suciedad” y “Vegetación”. La clase referida al funcionamiento normal de un módulo PV se denomina “Sin Anomalías”. La Figura 17 constituye una muestra de cómo se clasifican estas imágenes en la BD.

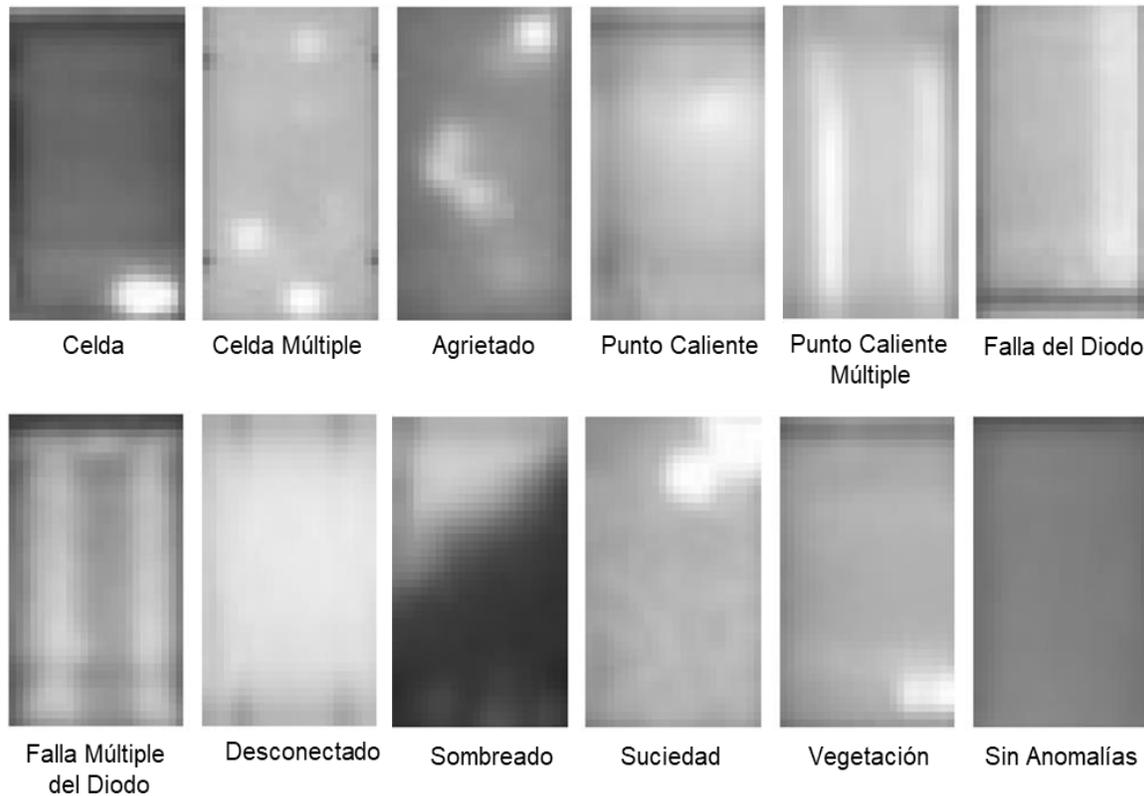


Figura 17. Muestra representativa de las imágenes según la clase. Fuente: Autora.

2.3 Preprocesamiento de los datos

Al inspeccionar las características de las diferentes clases que conforman la BD a emplear, se puede observar que existen solo cuatro clases referentes a defectos de degradación que contienen en su descripción puntos calientes. Basados en este análisis, se conformó una versión de la BD empleada en este trabajo, la cual solo contenía cinco clases: “Celda”, “Celda Múltiple”, “Punto Caliente”, “Punto Caliente Múltiple” y “Sin Anomalías”. En la Tabla 3 se describen las características de las clases pertenecientes a la BD “*InfraredSolarModules*” y se resaltan las que fueron finalmente seleccionadas para conformar la nueva base de datos.

Tabla 3. Características de la base de datos InfraredSolarModules

Nombre de clases	Imágenes	Descripción
Celda	1,877	Punto caliente que ocurre con geometría cuadrada en una sola celda.
Celda Múltiple	1,288	Puntos calientes que ocurren con geometría cuadrada en múltiples celdas.
Agrietado	941	Anomalía del módulo causada por grietas en la superficie del módulo.
Punto Caliente	251	Punto caliente en un módulo de película delgada.
Punto Caliente Múltiple	247	Múltiples puntos calientes en un módulo de película delgada.
Sombras	1,056	Luz solar obstruida por vegetación, estructuras artificiales o hileras adyacentes.
Falla del Diodo	1,499	Diodo de derivación activado, normalmente 1/3 del módulo.
Falla Múltiple del Diodo	175	Múltiples diodos de derivación activados, que normalmente afectan a 2/3 del módulo.
Vegetación	1,639	Paneles bloqueados por la vegetación.
Suciedad	205	Suciedad, polvo u otros residuos en la superficie del módulo.
Desconectado	828	Se calienta todo el módulo.
Sin Anomalías	10,000	Módulo solar con funcionamiento normal.

2.3.1 Técnica de aumento de datos

El conjunto de las clases seleccionadas de “*InfraredSolarModules*” para conformar la versión de la BD, consta de una cantidad considerable de imágenes. Sin embargo, es notable que las 10,000 muestras pertenecientes a la clase Sin Anomalías superan en 5.3 veces al conjunto de imágenes de la segunda clase más grande, Celda, la cual solo posee 1,877 imágenes. Dado que la distribución desbalanceada de los datos afecta tanto a la convergencia del entrenamiento como

a la capacidad de generalización del modelo entrenado [39], se determinó aplicar a la BD disponible la técnica de aumento de datos. Bajo el principio de que las transformaciones realizadas no distorsionaran las imágenes, ni provocaran la pérdida de alguna característica importante en ellas durante este proceso, se realizaron en total cinco transformaciones, las cuales se describen a continuación:

1. Volteo Horizontal: volteando de izquierda a derecha horizontalmente las imágenes.
2. Volteo Vertical: volteando de arriba hacia abajo verticalmente las imágenes.
3. Rotación $0.02 \times 2\pi$: aplicando rotaciones aleatorias a cada imagen en sentido horario, con un factor de $0.02 \times 2\pi$.
4. Rotación a 180° : realizando una rotación doble de 90° en sentido antihorario.
5. Traslación: aplicando traslaciones aleatorias, desplazando las imágenes hacia abajo y hacia la izquierda con factor de 0.05 en ambos casos.

En la Figura 18 se representa una imagen (original de la BD) perteneciente a la clase Celda y a continuación las diferentes transformaciones realizadas, como una muestra de la técnica de aumento de datos aplicada a la nueva BD.

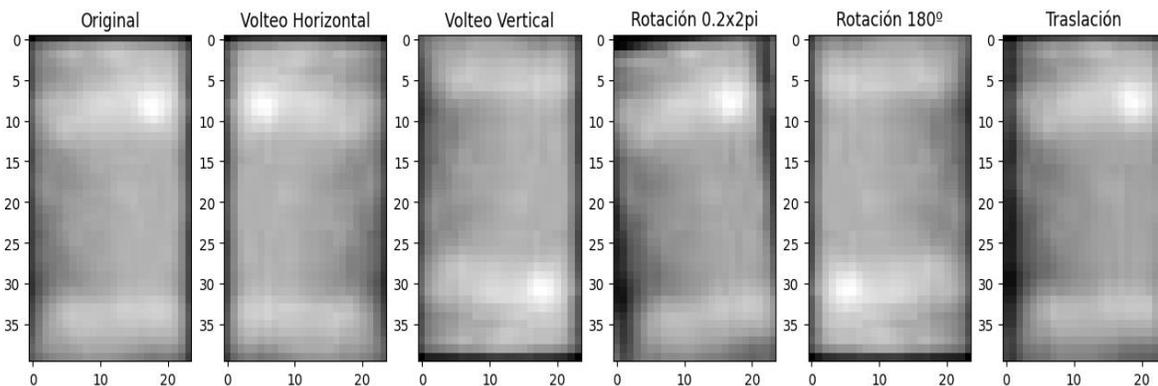


Figura 18. Imagen de muestra y sus transformaciones aplicando la técnica de aumento de datos a la BD. Fuente: Autora.

Una vez realizadas las transformaciones, a las imágenes iniciales de cada clase se le añadieron las aumentadas, incrementando con ello 6 veces el tamaño de la BD. Se procedió entonces a reconfigurar la BD, esta vez con solo dos clases: “Sin anomalías” y “Puntos calientes”, la cual contiene las imágenes pertenecientes a las

clases “Celda”, “Celda Multi”, “Puntos Calientes” y “Puntos Calientes Múltiples”. La Tabla 4 muestra las diferencias en la cantidad de imágenes de la BD antes y después del aumento de los datos, así como la nueva constitución de esta, la cual será empleada finalmente en el entrenamiento del modelo propuesto.

Tabla 4. Transformaciones en la base de datos al aplicar la técnica de aumento de datos.

<i>Antes</i>		<i>Después</i>		
Clases	Imágenes	Imágenes	Clases Finales	
Celda	1,877	11,262		
Celda Múltiple	1,288	7,728	21,960	Puntos Calientes
Punto Caliente	251	1,494		
Punto Caliente Múltiple	247	1,476		
Sin Anomalías	10,000		60,000	Sin Anomalías
TOTAL	13,663	81,960		2

2.4 Modelo de la red neuronal

La técnica de aprendizaje profundo escogida para detectar de manera automática la presencia de puntos calientes en las imágenes termográficas de la base de datos, emplea un modelo de CNN, inspirado en la arquitectura *AlexNet*, específicamente en la versión *Fused AlexNet* disponible en [59]. Esta versión fue implementada a partir de la arquitectura original, siendo optimizada para el entrenamiento empleando un único GPU.

2.4.1 Arquitectura *AlexNet* empleada

La arquitectura empleada es de tipo secuencial, emplea una única GPU y su estructura general se representa en la Figura 19. Está conformada por un total de 8 bloques: 5 de ellos contienen capas convolucionales y los 3 restantes, capas densas o FC. Dado que las imágenes a la entrada de la red poseen una dimensión de

24×40, fue necesario escalarlas en la capa de entrada a 224×224×1 debido a las especificaciones de la arquitectura original [30].

El primer bloque está compuesto por una capa convolucional de 96 filtros, de tamaño 11×11, paso de 4 y función de activación Relu; una capa de normalización y por último una capa de reducción por valor máximo (*Maxpoolig*), con ventana de tamaño 3×3 y paso de 2. El segundo bloque recibe a su entrada un tensor de dimensión 56×56×96 proveniente del anterior, y presenta una composición similar al primero, con diferencias en la capa convolucional, en cuyo caso aplica 256 filtros, de tamaño 5×5 y paso de 1; a su salida, produce un tensor de dimensión 27×27×256. El tercer y cuarto bloque, poseen ambos una capa de convolución con 384 filtros de tamaño 3×3 y paso de 1; aplican una capa de normalización y luego una función de activación Relu, generando a la salida un tensor de dimensión 13×13×384. El quinto bloque es similar a los dos primeros, pero en este caso la convolución emplea filtros de 256 tamaño 3×3 para un tensor de salida de dimensión 13×13×256.

A continuación, se aplica una capa de aplanamiento (*flatten*) para dar paso a tres bloques compuestos por capas FC. Los dos primeros, contienen una capa densa de 4096 neuronas y función de activación Relu, a la que se le añade una capa de *Dropout* con factor de 0.5 para evitar el riesgo de sobreajuste. En el último bloque, se encuentra la capa de clasificación con solo dos neuronas de salida y en la que se emplea como función de activación *Softmax* (Anexo 3).

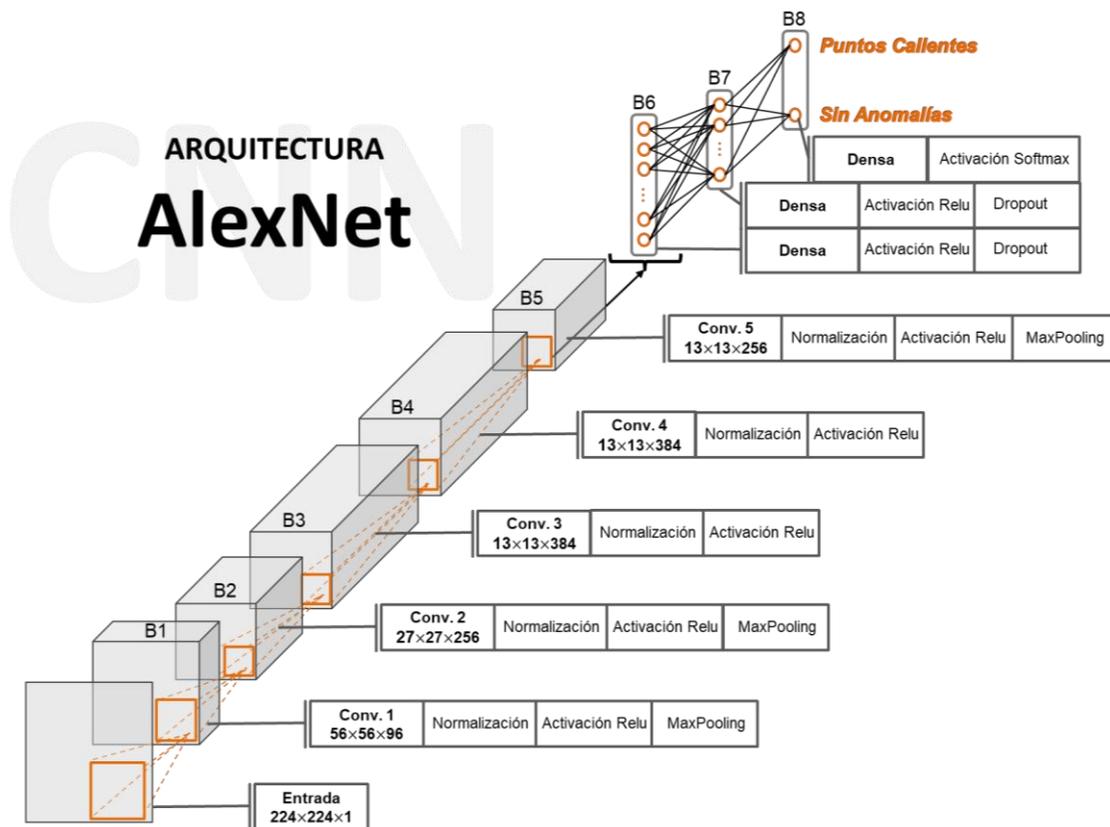


Figura 19. Estructura general de la CNN propuesta basada en la arquitectura optimizada de AlexNet. Fuente: Autora.

2.4.2 Métricas empleadas para la evaluación del modelo

Las métricas de evaluación del aprendizaje de modelos de CNN permiten determinar su rendimiento y comprender mejor su capacidad para cumplir los objetivos para los que fue entrenado. Dentro de las más empleados se pueden mencionar: la exactitud, precisión, matriz de confusión, exhaustividad (*recall*), F1, entre otros [32], [47]. Para evaluar el aprendizaje del modelo con la arquitectura propuesta, se utilizaron las métricas que a continuación se describen:

1. Matriz de confusión

Es una herramienta que permite visualizar por medio de una tabla el desempeño de un modelo que emplea el aprendizaje supervisado. La matriz de confusión es una matriz cuadrada de igual orden a la cantidad de clases dadas y cuyos elementos

representan, generalmente en porcentaje, las predicciones realizadas por el algoritmo en cada clase. Las filas de la matriz representan las clases reales y las columnas, las clases predichas. Las predicciones correctas son ubicadas en la diagonal principal, mientras que las incorrectas, son representadas con valores distintos a cero fuera de esta (Figura 20).

		Predicciones	
		Positivo	Negativo
Casos reales	Positivo	TP	FP
	Negativo	FN	TN

Figura 20. Matriz de confusión. TP: Verdadero Positivo, TN: Verdadero Negativo, FP: Falso Positivo, FN: Falso Negativo. Fuente: Autora.

2. Exactitud

Está determinado por la razón porcentual entre la cantidad de predicciones correctas realizadas por el modelo y el número total de predicciones clasificadas. Para cada ejemplo de datos, el modelo genera una salida en forma de distribución de probabilidad sobre las diferentes clases. La clase con la probabilidad más alta se considera la predicción del modelo. En términos de la matriz de confusión, su ecuación viene dada por:

$$Exactitud = \frac{TP + TN}{TP + TN + FP + FN} * 100\%$$

2.4.3 Método de visualización para la evaluación del modelo

La interpretación de modelos de redes neuronales, en la mayoría de los casos, puede suponer una tarea sumamente compleja debido al gran número de parámetros y operaciones internas que en ellos se producen. Sin embargo, conocer en qué medida influyen estos en las predicciones finales es de gran importancia para comprender las características en las que se basan dichos modelos. En este sentido, los sistemas de análisis visual constituyen una herramienta muy valiosa

para inspeccionar modelos de ANN. Los métodos de visualización desarrollados para este fin, están basados en técnicas de reducción de la dimensionalidad, preservando al máximo las características de los datos [60].

El algoritmo t-SNE (*T-distributed Stochastic Neighbor Embedding*, según su término en inglés) es una de las técnicas no lineales y no supervisadas más empleadas en la literatura especializada [60]. Permite analizar visualmente las relaciones existentes entre las representaciones aprendidas y las neuronas en modelos de ANN. Facilita además realizar exploraciones sobre la evolución entre las capas y las épocas de la red durante el proceso de aprendizaje, respaldando con ello la identificación de zonas de confusión al modelar cada objeto de alta dimensión como un punto bidimensional, reduciendo su tamaño de 2 a 3 veces. La distribución de puntos en el espacio se determina calculando la medida de similitud entre pares de puntos, la cual es optimizada luego por medio de una función de costo. En [61] se describe que el algoritmo t-SNE consiste en 3 pasos fundamentales:

1. Se determina la probabilidad condicional p_{ij} , definida como la similitud entre dos puntos vecinos x_i y x_j en el espacio de gran dimensión. Se calcula a partir de una distribución gaussiana centrada en cada punto x_i y la densidad medida para cada punto x_j bajo la varianza gaussiana σ . Luego este valor es normalizado para cada uno de estos puntos. Matemáticamente está dada por:

$$p_{ij} = \frac{\exp\left(-\|x_i - x_j\|^2 / 2\sigma^2\right)}{\sum_{k \neq l} \exp\left(-\|x_k - x_l\|^2 / 2\sigma^2\right)}$$

2. El espacio de baja dimensión creado (reducido 2 o 3 dimensiones) distribuye inicialmente las representaciones de los datos de manera aleatoria. El algoritmo calcula la probabilidad condicional de baja dimensión q_{ij} de los puntos y_i y y_j en el nuevo espacio dado por:

$$q_{ij} = \frac{\left(1 + \|y_i - y_j\|^2\right)^{-1}}{\sum_{k \neq l} \left(1 + \|y_k - y_l\|^2\right)^{-1}}$$

3. Para medir la fidelidad de la distribución realizada, se comparan los valores de las probabilidades condicionales p_{ij} y q_{ij} obtenidas de ambos espacios

utilizando como función de costo la divergencia de Kullback Leibler (KL). En este caso, KL es igual a la entropía cruzada aditiva de una constante:

$$C = D_{KL}(P\|Q) = \sum_i \sum_j p_{ij} \log \left(\frac{p_{ij}}{q_{ij}} \right)$$

La función de costo es luego minimizada en cada punto empleando el gradiente descendiente, con el objetivo de aproximar lo mejor posible el espacio reducido al de gran dimensión por medio de la ecuación:

$$\frac{\partial C}{\partial y_i} = 4 \sum_j (p_{ij} - q_{ij})(y_i - y_j) (1 + \|y_i - y_j\|^2)^{-1}$$

2.5 Descripción de los experimentos realizados

Para evaluar el rendimiento del modelo propuesto se realizaron un total de 20 experimentos. En todos los casos se empleó la arquitectura de CNN propuesta basada en *Fused AlexNet*.

En los experimentos realizados se aplicó la técnica de retención repetida, considerada como la técnica más simple de evaluación de modelos [62]. Consiste en particionar aleatoriamente el total del conjunto de datos en dos subconjuntos: uno de entrenamiento, con el cual se entrenará el modelo y otro de validación, cuyos datos se utilizarán para modificar los parámetros de ajuste y evaluar su desempeño. Con respecto a lo anterior, [19] refiere que en modelos de redes neuronales, resulta necesario disponer de un tercer subconjunto de datos, en este caso uno de prueba o evaluación, para determinar la capacidad de generalización del modelo sobre datos desconocidos que no pertenecen a ninguno de los subconjuntos previamente mencionados.

En [62] se explica que una forma obtener una estimación del rendimiento del modelo más sólida y menos sesgada consiste en repetir este método k veces para diferentes semillas aleatorias y a partir de los resultados obtenidos, calcular el rendimiento promedio sobre el conjunto de prueba en las k repeticiones. Considerando estos análisis, las imágenes de la BD se particionaron en tres subconjuntos: uno destinado para el entrenamiento T , otro para la validación V y otro de prueba E .

En este caso el número de repeticiones para la aplicación de esta técnica es $k = 20$, asegurando con ello que todas las imágenes pasen por el conjunto de validación al menos una vez con un 95% de probabilidad, como se muestra en la Figura 21:

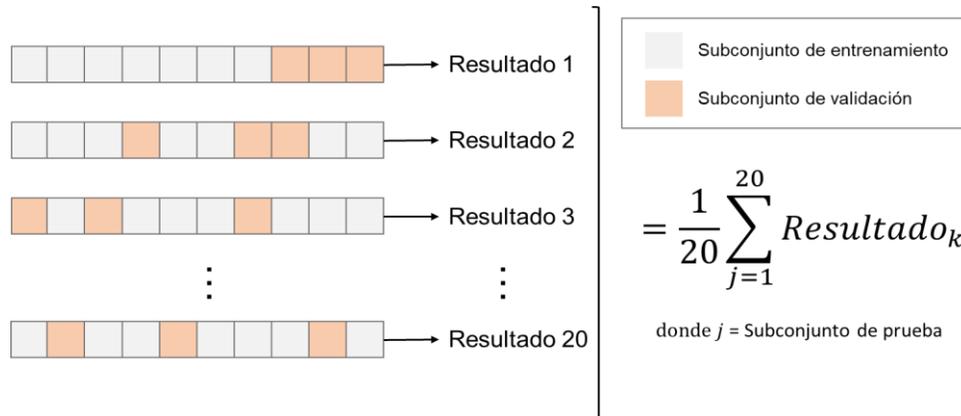


Figura 21. Representación de la técnica de retención repetida 20 veces. Fuente: Autora.

Las divisiones aleatorias de los subconjuntos de entrenamiento y validación se realizaron garantizando el balance de las clases, para lo cual se estableció que cada uno de ellos contendría una representación de ambas. Se determinó entonces que el 90% de las imágenes de la BD serían destinadas al subconjunto de entrenamiento, resultando en un total de 39,528 imágenes, de las cuales 19,764 pertenecerían a la clase de “Puntos Calientes” y 19,764 a “Sin Anomalías”.

La cantidad de imágenes pertenecientes al subconjunto de validación fue calculada para representar aproximadamente el 10% del subconjunto de entrenamiento. A partir de este valor, se determinó que las clases “Puntos Calientes” y “Sin Anomalías” contendrían 1,976 imágenes cada una, sumando en un total de 3,952 imágenes en todo el subconjunto.

De forma general, durante el entrenamiento, el subconjunto de entrenamiento T quedó aleatoriamente dividido en otros dos subconjuntos: T_1 (entrenamiento) con el 85% de las imágenes, y V_1 (validación) con el 15% restante, repitiendo este proceso $k = 20$ veces con diferentes semillas comprendidas en un intervalo de [10, 210) con un paso de 10 valores. De esta manera, se obtuvieron 20 modelos, cada uno entrenado con conjuntos de entrenamiento y validación diferentes, pero evaluados sobre el mismo conjunto de prueba.

Para evitar el sobreajuste, se añadieron capas de “*dropout*” y las técnicas de la parada temprana y la disminución de la tasa de aprendizaje, cuyos parámetros se ajustaron de manera experimental. La paciencia se ajustó de forma tal que se realizaran al menos dos disminuciones de los valores de la tasa de aprendizaje antes de que esta se agotara en la parada temprana. Se empleó el optimizador Adam y como función de pérdida, la entropía cruzada categórica. Se utilizó, como parámetro a monitorear el “*val-loss*”, correspondiente a la pérdida de dicha función sobre el conjunto de validación.

Una vez finalizado el entrenamiento con los subconjuntos T_1 y V_1 , se evaluó la capacidad de generalización del modelo sobre el subconjunto de prueba E . Para ello se empleó como monitor el “*val-loss*” sobre dicho subconjunto. La figura 22 muestra la distribución realizada al conjunto de imágenes de la BD empleada en los subconjuntos de entrenamiento, validación y evaluación.

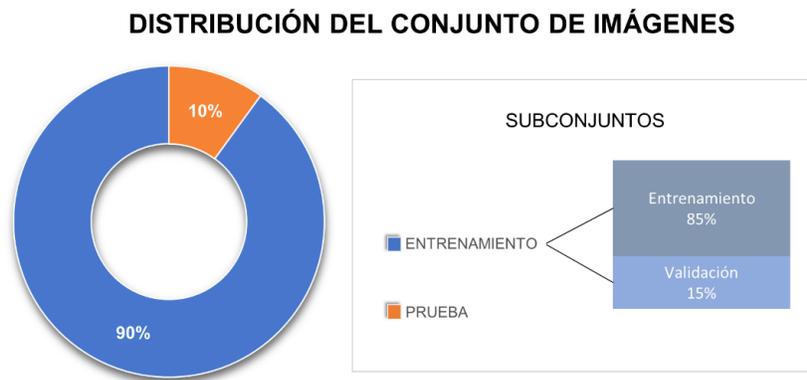
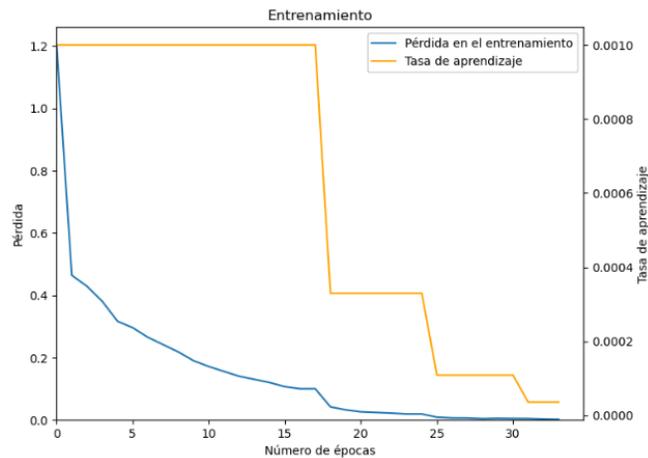


Figura 22. Distribución del conjunto de imágenes en los subconjuntos de entrenamiento, validación y prueba. Fuente: Autora.

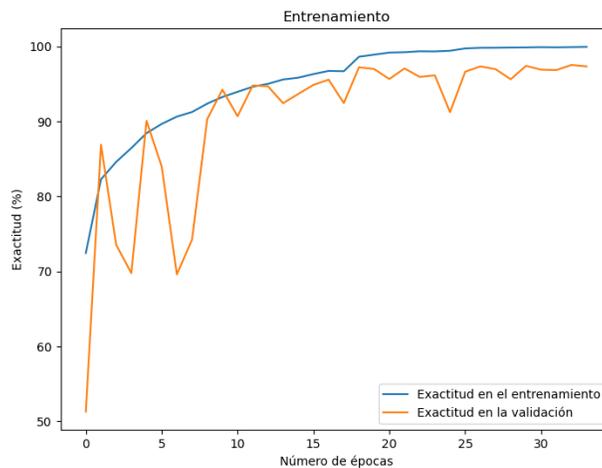
2.6 Resultados de los experimentos

A continuación, en la Figura 23 se visualizan dos gráficas que describen el proceso de aprendizaje del modelo durante el entrenamiento. Los datos mostrados en la primera gráfica (Figura 23 a), corresponden a la evolución del entrenamiento según las métricas de pérdida y tasa de aprendizaje con respecto al número de épocas. En ella se observan los efectos de la técnica de disminución de la tasa de

aprendizaje sobre la función de pérdida, propiciando que la red logre una convergencia cada vez más rápida con menores errores, lo que demuestra un buen desempeño del modelo. La Figura 23 b muestra las curvas de exactitud sobre los subconjuntos de entrenamiento y validación con respecto al número de épocas. Los valores alcanzados con el subconjunto de validación permiten evaluar satisfactoriamente el rendimiento del aprendizaje del modelo. La curva de exactitud sobre el subconjunto de validación no revela indicadores de sobreajuste en el modelo, mostrando valores aún comparables con los de la curva de entrenamiento.



a)



b)

Figura 23. Proceso de aprendizaje del modelo durante el entrenamiento con respecto al número de épocas: a) según las métricas de pérdida y tasa de aprendizaje, b) según los valores de exactitud en los subconjuntos de entrenamiento y validación. Fuente: Autora.

Una vez entrenado el modelo, se evaluó el mismo sobre el subconjunto de prueba, compuesto por las imágenes que no fueron empleadas en el proceso de entrenamiento (ver Figura 22). En la Tabla 5 se resumen, para cada una de las semillas empleadas, los valores correspondientes a la función de pérdida y la exactitud alcanzados, así como el valor promedio de los mismos. Los mejores resultados se resaltan en negrita.

Tabla 5. Resultados obtenidos en la evaluación de la arquitectura propuesta sobre el subconjunto de prueba.

Semilla	Pérdida	Exactitud (%)
10	0.2152	93.10
20	0.2222	94.24
30	0.3024	93.99
40	0.2235	92.76
50	0.4375	94.63
60	0.4578	93.90
70	0.4774	47.75
80	0.4359	93.56
90	0.5413	92.12
100	0.3799	93.42
110	0.4627	94.38
120	0.2323	94.81
130	0.3432	94.42
140	0.2172	92.92
150	0.2828	94.35
160	0.4034	94.79
170	0.2935	94.22
180	0.2627	93.31
190	0.3131	93.40
200	0.2321	93.06
Promedio	0.3368	93.195

La Figura 24 muestra la matriz de confusión obtenida también sobre el subconjunto de prueba. A partir de ella se observa una buena discriminación de las dos clases, siendo notable una mejor clasificación de las imágenes “Sin Anomalías” en un 94.57% frente a las imágenes con “Puntos Calientes” con el 92.97%. Además de lo anterior, la matriz obtenida resume que solo el 5.43% de las imágenes sin anomalías se clasifican como pertenecientes a la clase de “Puntos Calientes”, mientras que el 7.03% de las imágenes con puntos calientes se clasifican “Sin Anomalías”. Con ello se puede concluir que los resultados alcanzados se consideran buenos para un primer intento del uso de estos clasificadores en la detección de puntos calientes por parte de la investigadora.

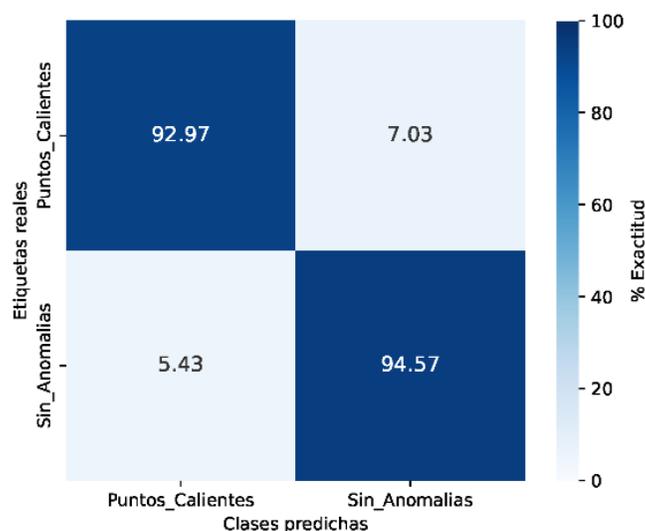


Figura 24. Matriz de confusión sobre el subconjunto de prueba. Fuente: Autora.

En la Figura 25 se muestra la representación obtenida al aplicar el método t-SNE para representar las proyecciones espaciales de las características extraídas por la arquitectura en 2D (2 Dimensiones) antes de entrenar el modelo (Figura 25 a) y una vez entrenado, a la entrada de la segunda capa densa (Figura 25 b) y de la capa de clasificación (Figura 25 c). A partir de estas figuras, se observa la distribución desordenada de las imágenes de entrada al modelo según sus clases correspondientes (Figura 25 a) y la manera en que la red va logrando discriminar estas clases (Figura 25 b) a medida que se acerca a la capa de clasificación (Figura 25 c). Con respecto a esta última, es notable la buena separación entre las clases

“Puntos_Calientes” y “Sin_Anomalias”; sin embargo, dado que el porcentaje de exactitud alcanzada no es de 100%, aún se observan pequeños puntos mezclados de ambas clases, por lo tanto, los resultados alcanzados tienen total correspondencia con la matriz de confusión mostrada en la Figura 24.

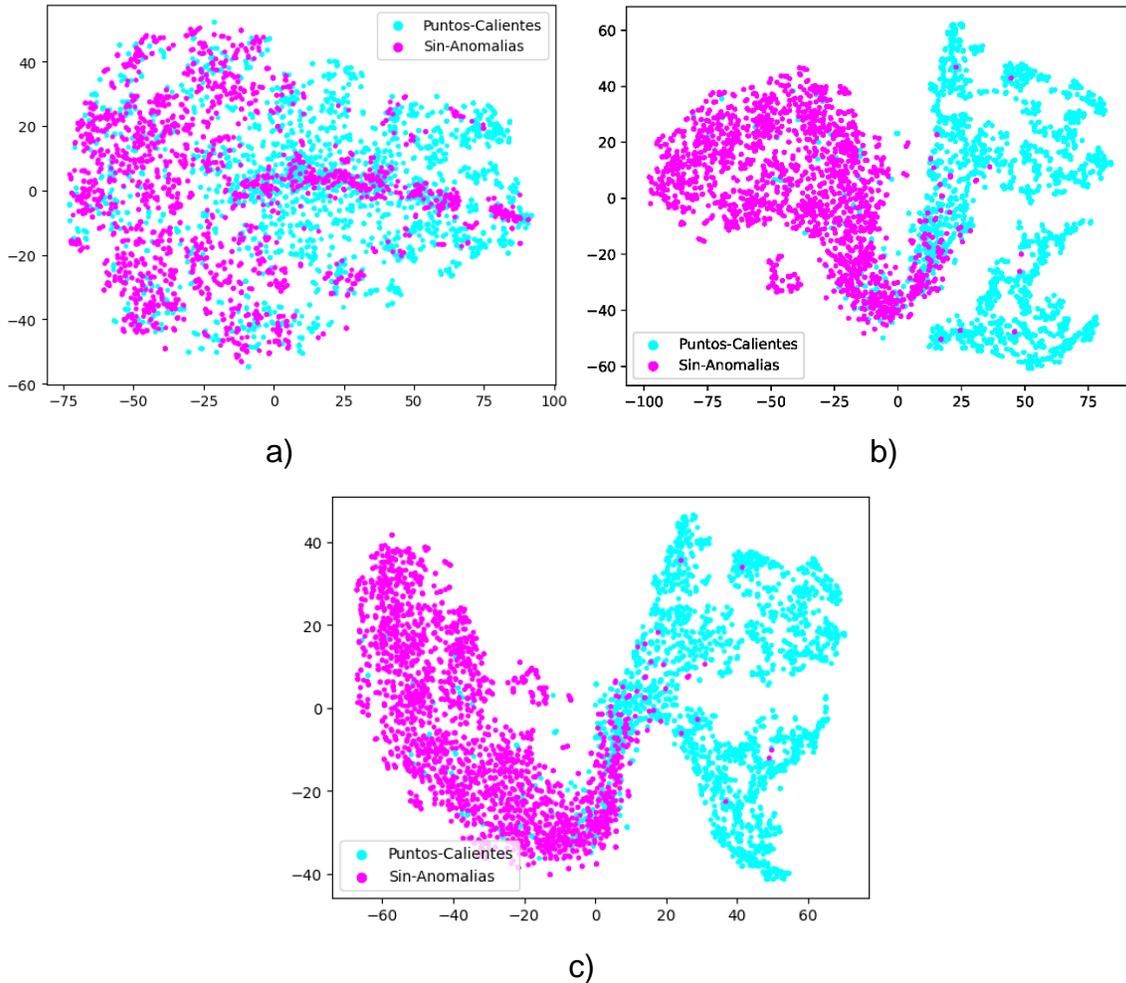


Figura 25. Visualización del método t-SNE: a) antes del entrenamiento, b) a la entrada de la segunda capa densa, c) a la entrada de la capa de clasificación. Fuente: Autora.

2.7 Discusión de los resultados

La presente investigación propone un método automático para la detección de puntos calientes en módulos PV, mediante el empleo de imágenes termográficas y técnicas de aprendizaje profundo. Estas herramientas constituyen precisamente la tendencia a escala global, y facilitan la detección temprana de estos defectos de

degradación al mejorar la confiabilidad de los sistemas fotovoltaicos y aumentar su eficiencia para la generación de electricidad.

Un estudio realizado en el año 2022 [32], aborda la detección de puntos calientes a partir imágenes termográficas pertenecientes a dos clases extraídas de la base de datos internacional “*InfraredSolarModules*”: “Puntos Calientes” y “Sin Anomalías”. La clase “Puntos Calientes” está compuesta por imágenes pertenecientes a las clases “Puntos Calientes” y “Puntos Calientes Múltiples”. Tras aplicar la técnica de aumento de datos a estas imágenes, se compararon sobre el conjunto de imágenes seis modelos de aprendizaje profundo: *AlexNet*, *GoogLeNet*, *ShuffleNet*, *SqueezeNet*, *ResNet-50*, y *MobileNet-v2*. Dichos modelos fueron entrenados para 40 épocas, empleando el optimizador SGD con factor de tasa de aprendizaje en $1e^{-3}$. De acuerdo a los resultados obtenidos, la arquitectura de red neuronal convolucional *AlexNet* mostró el mejor rendimiento con un valor de exactitud de 98.65%. A pesar de los buenos resultados obtenidos en el estudio en cuestión, la selección de solo dos clases para conformar la clase “Puntos Calientes” excluyó otras como “Celda” y “Celda Múltiple”, que de igual manera contenían en su descripción la aparición de puntos calientes, como se demostró en el Epígrafe 2.3. De aquí que los modelos entrenados solo reconocen puntos calientes con una forma específica y en una única región del módulo PV, desaprovechando la información contenida en la base de datos para realizar la detección de este tipo de defecto de degradación con una mayor cobertura en el dispositivo.

Para superar la limitación anterior, en este trabajo se consideraron las clases: “Puntos calientes” y “Sin anomalías”, incluyendo las imágenes pertenecientes a las clases “Celda”, “Celda Multi”, “Puntos Calientes” y “Puntos Calientes Múltiples” dentro de la clase “Puntos calientes”. La tabla 6 muestra las características de la base de datos considerada en [32] y la utilizada en la siguiente investigación.

Tabla 6. Características de las bases de datos empleadas en ambas investigaciones.

Estudio en [32]			Presente investigación		
Clases		Imágenes	Clases		Imágenes
Puntos Calientes	Punto Caliente	251	Puntos Calientes	Celda	1,877
	Punto Caliente Múltiple	247		Celda Múltiple	1,288
Sin Anomalías		10,000		Punto Caliente	251
				Punto Caliente Múltiple	247
			Sin Anomalías		10,000
TOTAL		10,498			13,663

Al igual que en [32], en este trabajo se aplicó sobre el conjunto de imágenes la técnica de aumento de datos para elevar la cantidad de muestras a la entrada del modelo propuesto. A partir de los resultados obtenidos en el estudio anterior, se determinó implementar la arquitectura de red neuronal convolucional *AlexNet* por ser la que mejor desempeño mostró en [32]. Resulta importante señalar que, para obtener mejor eficiencia en el proceso de entrenamiento se incorporaron técnicas de regularización, de parada temprana y decaimiento de la tasa de aprendizaje. La Figura 26 muestra, a modo de comparación, los resultados obtenidos aplicando la misma estrategia de entrenamiento realizada en [32] y la implementada en este trabajo. Se observa que, al incorporar las técnicas de regularización de la parada temprana y la reducción de la tasa de aprendizaje, la función de pérdida tiene un comportamiento superior al de la que se obtiene fijando previamente el número de épocas del entrenamiento (40 épocas) como se hace en [32]. Se muestra también que con estas modificaciones, el entrenamiento se detiene sobre la época 33 (7 épocas antes que el total de épocas establecidas en [32]) ya que al monitorear la función de pérdida sobre el conjunto de validación se determinó que el rendimiento del modelo empeoraba luego de este momento, lo que evitó que se produjera un sobreajuste del mismo y propició la obtención de un modelo más robusto y preciso.

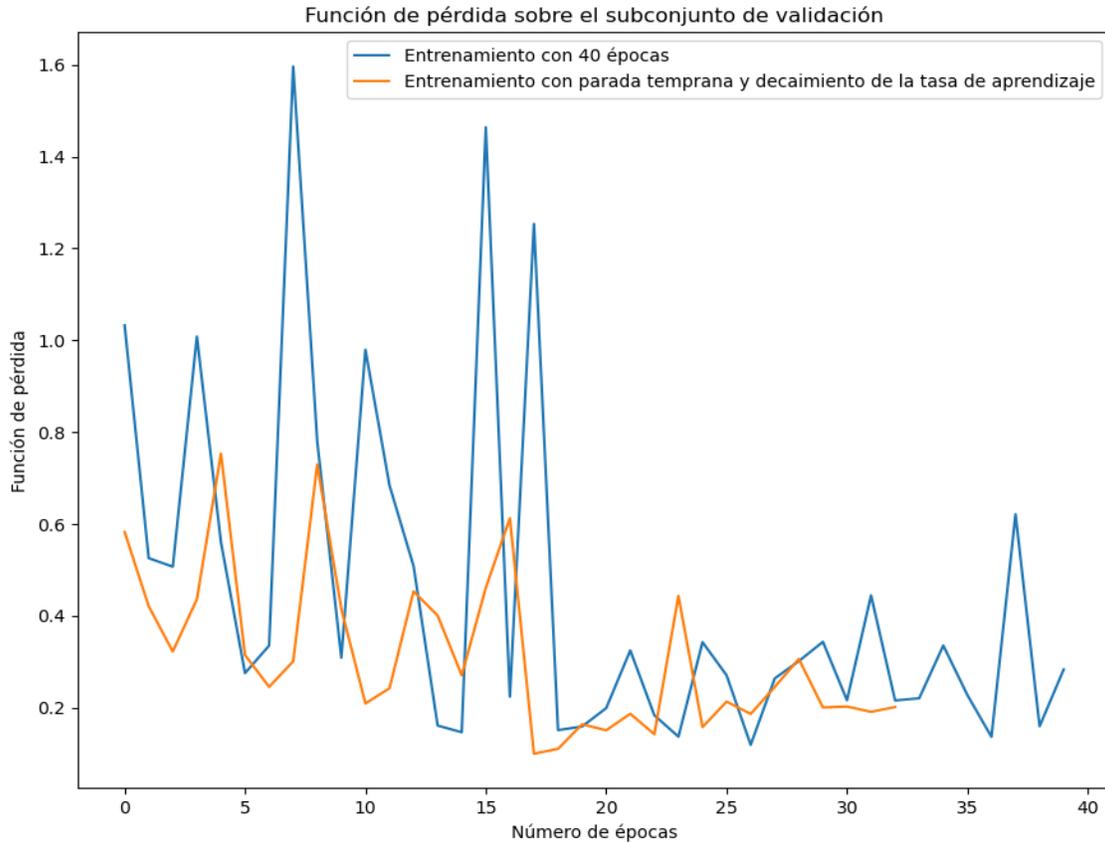


Figura 26. Comparación entre las funciones de pérdida sobre el subconjunto de validación. Fuente: Autora.

En la figura 27 se puede comprobar que no solo existen diferencias notorias entre las funciones de pérdida anteriormente mostradas, sino que los valores de exactitud obtenidos mejoran con respecto al entrenamiento donde no se considera la aplicación de las técnicas de regularización empleadas en este trabajo.

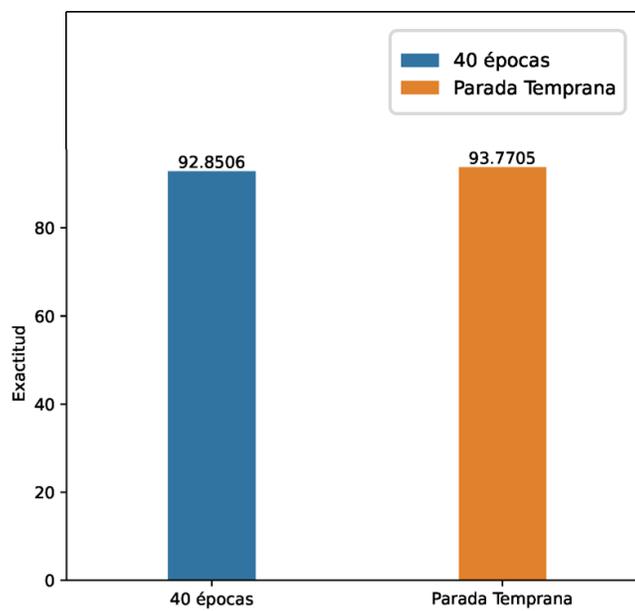


Figura 27. Comparación entre los valores de exactitud obtenidos sobre el subconjunto de prueba. Fuente: Autora.

2.8 Conclusiones parciales

En este capítulo, la propuesta de una arquitectura de red neuronal convolucional para la detección de forma automática de puntos calientes presentes en imágenes termográficas permite concluir lo siguiente:

1. A diferencia del estudio de referencia del que parte la presente investigación, que incluyó solo las clases “Puntos Calientes” y “Puntos Calientes Múltiples” para conformar la nueva clase “Puntos Calientes”, en este trabajo se añadieron además las clases “Celda” y “Celda Multi”. Esto provocó que el proceso de entrenamiento de la arquitectura propuesta tuviera una mayor complejidad, ya que abarcó mucha más información relacionada con estos defectos de degradación; aunque los resultados obtenidos no fueron superiores.
2. En la evaluación de los modelos obtenidos en cada experimento sobre las imágenes de prueba, se obtuvo un rendimiento superior al 93% de exactitud promedio, lo cual se considera un resultado satisfactorio.

3. Las técnicas de regularización de la parada temprana y el decaimiento de la tasa de aprendizaje incorporadas al proceso de entrenamiento del modelo, produjeron un comportamiento más estable del mismo, aportando mejoras no solo respecto al tiempo de entrenamiento sino también al valor de la función de pérdida sobre los subconjuntos de entrenamiento y de validación.

CONCLUSIONES

El desarrollo de algoritmos cada vez más potentes para la detección de anomalías en los módulos PV constituye una tendencia internacional y un nicho de investigación promisorio para contribuir a maximizar la utilidad y eficiencia de esta tecnología. En esta investigación, se propone el uso de las técnicas de aprendizaje profundo para la detección de puntos calientes a partir de imágenes termográficas obtenidas de bases de datos internacionales, con vistas a una futura aplicación del método desarrollado en los parques solares instalados en Cuba. Como resultado del presente trabajo, es posible afirmar que los objetivos trazados fueron alcanzados, permitiendo arribar a las siguientes conclusiones:

1. En Cuba, los estudios que abordan los métodos empleados para la detección de puntos calientes en módulos fotovoltaicos, se limitan a la inspección visual de estos defectos a partir de imágenes termográficas. Esto provoca que la detección de puntos calientes sea un proceso lento, lo que ocasiona una disminución de la vida útil de estos dispositivos y aumenta el costo de mantenimiento de las instalaciones.
2. El modelo de red neuronal convolucional propuesto se basó en la arquitectura *Fused AlexNet* y se evaluó sobre la base de datos internacional "*InfraredSolarModules*", mostrando un rendimiento superior al 93% de exactitud sobre imágenes de prueba. El resultado alcanzado se considera positivo para la detección de puntos calientes y permite que el modelo propuesto se tome en cuenta en la implementación de soluciones autóctonas que tributen a la soberanía tecnológica y a la autonomía energética del país.
3. Las mejoras incorporadas al proceso de entrenamiento del modelo empleando las técnicas de regularización, permitieron lograr un modelo más estable, robusto y con menor riesgo de sobreajuste de los parámetros respecto al estudio precedente.

RECOMENDACIONES

Con vista a continuar el desarrollo de la presente investigación, se consideran como recomendaciones las siguientes:

- La aplicación del método automático propuesto para la detección de puntos calientes a partir de imágenes termográficas tomadas de los módulos fotovoltaicos instalados en los parques solares de Cuba.
- La incorporación de un procedimiento de segmentación en las imágenes con vista a ampliar la aplicabilidad del modelo propuesto sobre un conjunto más amplio de bases de datos internacionales.

BIBLIOGRAFÍA

- [1] IRENA, “Renewable capacity highlights,” *Renew. Capacit. highlights*, no. March, p. 3, 2021.
- [2] M. Korkeakoski and M. L. Filgueiras Sainz de Rozas, “Una mirada a la transición de la matriz energética cubana,” *Ing. Energética*, vol. 43, no. 3, pp. 40–47, 2022.
- [3] Ministerio de Energía y Minas, “Solar.” Accessed: Oct. 11, 2023. [En línea]. Disponible en: <https://www.minem.gob.cu/es/actividades/energias-renovables-y-eficiencia-energetica/solar>
- [4] B. Li, C. Delpha, D. Diallo, and A. Migan-Dubois, “Application of Artificial Neural Networks to photovoltaic fault detection and diagnosis: A review,” *Renew. Sustain. Energy Rev.*, vol. 138, p. 110512, 2021.
- [5] S. Morales Galvez and A. Martinez, “Preventive diagnosis of photovoltaic facilities based on the interpretation of infrared images,” *ITEGAM-JETIA*, vol. 6, no. 25, pp. 16–20, 2020, doi: <https://doi.org/10.5935/jetia.v6i25.686>.
- [6] A. Einstein, “Heurística de la generación y conversión de la luz,” *Ann. Phys.*, vol. 17, no. 1, pp. 549–560, 1905.
- [7] I. Romero *et al.*, *Manual de Generación Distribuida Solar Fotovoltaica*, 1st ed. Argentina: Secretaría de Gobierno de Energía, 2019.
- [8] HelioEsfera, “Diagrama de un sistema fotovoltaico.” Accessed: Oct. 27, 2023. [En línea]. Disponible en: <https://www.helioesfera.com/diagrama-sistema-fotovoltaico/>
- [9] D. C. Jordan, T. J. Silverman, J. H. Wohlgemuth, S. R. Kurtz, and K. T. VanSant, “Photovoltaic failure and degradation modes,” *Prog. Photovoltaics Res. Appl.*, vol. 25, no. 4, pp. 318–326, 2017, doi: [doi:10.1002/pip.2866](https://doi.org/10.1002/pip.2866).
- [10] D. Castrillón Ocampo, “Detección de puntos calientes en sistemas fotovoltaicos,” Instituto Tecnológico Metropolitano - ITM, 2022.
- [11] *et al.* Ali MU, Saleem S, Masood H, Kallu KD, Masud M, Alvi MJ, “Early hotspot detection in photovoltaic modules using color image descriptors: An infrared thermography study,” *Int. J. Energy Res.*, vol. 46, pp. 774–785, 2022, doi: <https://doi.org/10.1002/er.7201>.

- [12] M. Ma, H. Liu, Z. Zhang, P. Yun, and F. Liu, "Rapid diagnosis of hot spot failure of crystalline silicon PV module based on IV curve," *Microelectron. Reliab.*, vol. 100, p. 113402, 2019.
- [13] R. Haskell, "Why Hot Spots are a Problem," CHERPSolar. Accessed: Oct. 25, 2023. [En línea]. Disponible en: <https://www.cherpsolar.org/single-post/2018/05/20/why-hot-spots-are-a-problem>
- [14] J. Benavides Esteva, R. Díaz Suárez, A. Roig Rassi, and L. Vaillant Roca, "Electroluminiscencia de módulos de silicio policristalino," *Ing. Energética*, vol. 43, no. 2, pp. 60–69, 2022.
- [15] J. A. Tsanakas, L. Ha, and C. Buerhop, "Faults and infrared thermographic diagnosis in operating c-Si photovoltaic modules: A review of research and future challenges," *Renew. Sustain. energy Rev.*, vol. 62, pp. 695–709, 2016.
- [16] E. Kaplani, "Detection of degradation effects in field-aged c-Si solar cells through IR thermography and digital image processing," *Int. J. Photoenergy*, vol. 2012, 2012.
- [17] T. M. Mitchell, "Does machine learning really work?," *AI Mag.*, vol. 18, no. 3, p. 11, 1997, doi: <https://doi.org/10.1609/aimag.v18i3.1303>.
- [18] A. González Muñoz, "Aplicaciones de técnicas de inteligencia artificial basadas en aprendizaje profundo (deep learning) al análisis y mejora de la eficiencia de procesos industriales," Universidad de Oviedo, 2018.
- [19] D. Milanés Hermosilla, "Arquitecturas de redes neuronales para la clasificación de tareas de imaginación motora," Universidad de Oriente, 2022.
- [20] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015, doi: 10.1038/nature14539.
- [21] E. Acevedo, A. Serna, and E. Serna, "Principios y características de las redes neuronales artificiales," *Desarro. e innovación en Ing.*, vol. 173, pp. 173–183, 2017.
- [22] F. Izaurieta and C. Saavedra, "Redes neuronales artificiales," *Dep. Física, Univ. Concepción Chile*, 2000.
- [23] S. Sharma, S. Sharma, and A. Athaiya, "Activation functions in neural networks," *Towar. Data Sci.*, vol. 6, no. 12, pp. 310–316, 2017.

- [24] D. Peralta, A. Herrera, and F. Herrera, "Un estudio sobre el preprocesamiento para Redes Neuronales Profundas y Aplicación sobre Reconocimiento de Dígitos Manuscritos," in *Actas de la XVII Conferencia de la Asociación Española para la Inteligencia Artificial*, Universidad de Salamanca, Ed., Salamanca, 2020, pp. 867–876.
- [25] N. U. Q. Mamani, "Redes Neuronales Artificiales, Metodología de Desarrollo y Aplicaciones." 2002.
- [26] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, vol. 323, no. 6088, pp. 533–536, 1986.
- [27] K. Fukushima, "Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position," *Biol. Cybern.*, vol. 36, no. 4, pp. 193–202, 1980.
- [28] M. G. Villanueva and L. R. Muñoz, "Diseño de una Arquitectura de Red Neuronal Convolutiva para la clasificación de objetos," *Cienc. Nicolaita*, no. 81, pp. 46–61, 2020.
- [29] G. et al. CIPRIANI, "Convolutional neural network for dust and hotspot classification in PV modules.," *Energies*, vol. 13, p. 6357, 2020, doi: <https://doi.org/10.3390/en13236357>.
- [30] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," *Adv. Neural Inf. Process. Syst.*, vol. 25, 2012.
- [31] A. Abd Almisreb, N. Jamil, and N. M. Din, "Utilizing AlexNet deep transfer learning for ear recognition," in *2018 fourth international conference on information retrieval and knowledge management (CAMP)*, IEEE, 2018, pp. 1–5. doi: 10.1109/INFRKM.2018.8464769.
- [32] H. Acikgoz, D. Korkmaz, and Ç. Dandil, "Classification of Hotspots in Photovoltaic Modules with Deep Learning Methods," *Turkish J. Sci. Technol.*, vol. 17, no. 2, pp. 211–221, 2022, doi: 10.55525/tjst.1158854.
- [33] D. Pérez-Aguilar, R. Risco-Ramos, and L. Casaverde-Pacherrez, "Transfer learning en la clasificación binaria de imágenes térmicas transfer learning for binary classification of thermal images," *Ingenius*, vol. 550, no. 26, p. 4, 2021, doi:

10.17163/ings.n26.2021.07.

- [34] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770–778.
- [35] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *arXiv Prepr. arXiv1409.1556*, 2014, doi: <https://doi.org/10.48550/arXiv.1409.1556>.
- [36] S. Liu and W. Deng, "Very deep convolutional neural network based image classification using small training sample size," in *2015 3rd IAPR Asian conference on pattern recognition (ACPR)*, IEEE, 2015, pp. 730–734. doi: 10.1109/ACPR.2015.7486599.
- [37] J. Xiao, J. Wang, S. Cao, and B. Li, "Application of a novel and improved VGG-19 network in the detection of workers wearing masks," in *Journal of Physics: Conference Series*, IOP Publishing, 2020, p. 12041. doi: 10.1088/1742-6596/1518/1/012041.
- [38] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 4510–4520.
- [39] D. Korkmaz and H. Acikgoz, "An efficient fault classification method in solar photovoltaic modules using transfer learning and multi-scale convolutional neural network," *Eng. Appl. Artif. Intell.*, 2022, doi: 10.1016/j.engappai.2022.104959.
- [40] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," in *International conference on machine learning*, pmlr, 2015, pp. 448–456.
- [41] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929–1958, 2014.
- [42] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv Prepr. arXiv1412.6980*, 2014.
- [43] L. Prechelt, "Automatic early stopping using cross validation: quantifying the criteria,"

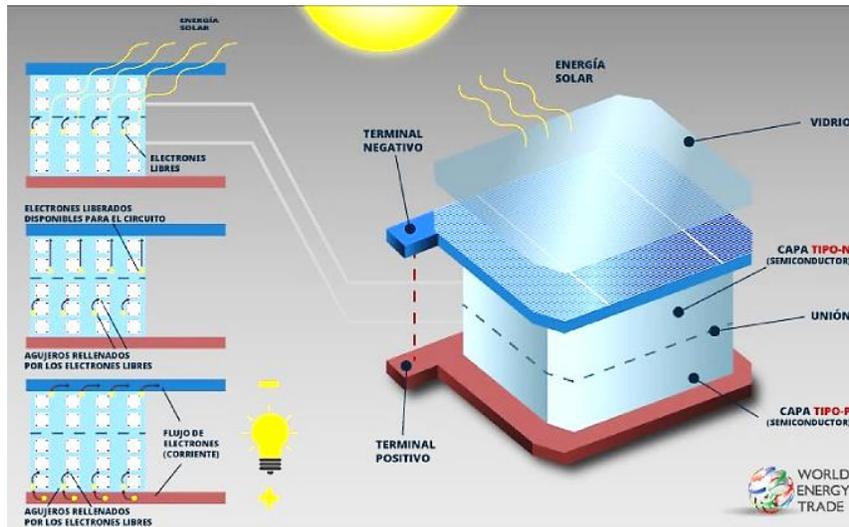
Neural networks, vol. 11, no. 4, pp. 761–767, 1998.

- [44] S. Gayathri Monicka, D. Manimegalai, M. Karthikeyan, and R. Gunasekari, “Image Processing Based Hot-Spot Detection on Photovoltaic Panels,” *Int. J. Intell. Syst. Appl. Eng.*, 2023.
- [45] J. Jordán Tomás, “Diseño de un método usando técnicas de inteligencia artificial y machine learning con Matlab para el mantenimiento y diagnóstico de fallos en paneles solares.” Universitat Politècnica de València, pp. 60-, 2023.
- [46] M. Hojabri, S. Kellerhals, G. Upadhyay, and B. Bowler, “IoT-Based PV Array Fault Detection and Classification Using Embedded Supervised Learning Methods,” *Energies*, vol. 15, no. 6, p. 2097, 2022.
- [47] L. E. Montañez, “Termografía Aerea Autónoma de paneles Fotovoltaicos,” 2021. [En línea]. Disponible en: <https://cio.repositorioinstitucional.mx/jspui/bitstream/1002/1217/1/18000.pdf>
- [48] U. Otamendi, I. Martínez, M. Quartulli, I. G. Olaizola, E. Viles, and W. Cambarau, “Segmentation of cell-level anomalies in electroluminescence images of photovoltaic modules,” *Sol. Energy*, vol. 220, pp. 914–926, 2021.
- [49] Á. H. Herraiz, A. P. Marugán, and F. P. G. Márquez, “Photovoltaic plant condition monitoring using thermal images analysis by convolutional neural network-based structure,” *Renew. Energy*, vol. 153, pp. 334–348, 2020.
- [50] Ministerio de Energía y Minas, “Políticas y Lineamientos.” Accessed: Sep. 26, 2023. [En línea]. Disponible en: <https://www.minem.gob.cu/es/actividades/energias-renovables-y-eficiencia-energetica/politicas-y-lineamientos>
- [51] Ministerio de Energía y Minas, *Decreto Ley No. 345, “Del desarrollo de las fuentes renovables y el uso eficiente de la energía,”* vol. 95. 2019, p. 26.
- [52] ONU, “Objetivos de Desarrollo Sostenible,” Agenda común. Accessed: Sep. 27, 2023. [En línea]. Disponible en: <https://www.un.org/es/common-agenda/sustainable-development-goals>
- [53] ONEI, “Anuario Estadístico De Cuba 2020 Completo,” *Anu. Estadístico Cuba 2020*, p. 482, 2021.

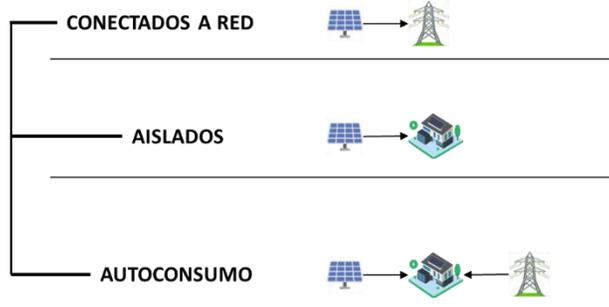
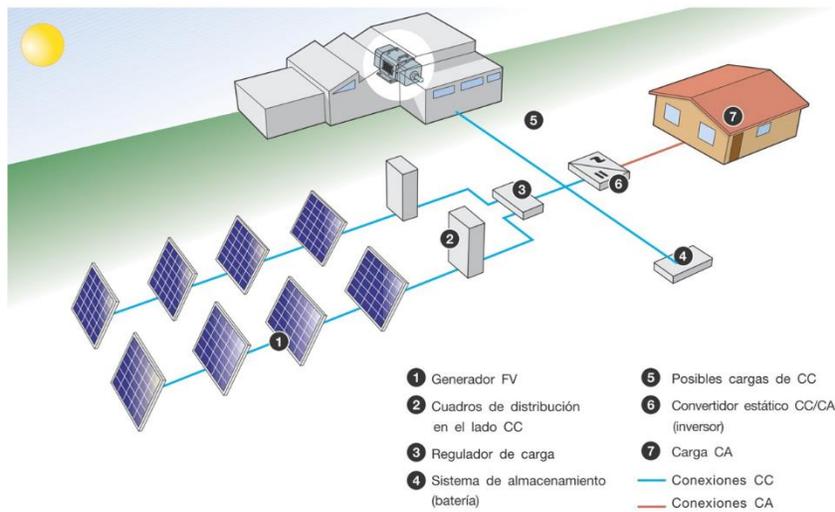
- [54] J. P. Monteagudo-Yanes and R. Jiménez-Borges, "Potencialidades del uso de la energía solar en la sede central de la Universidad de Cienfuegos," *Rev. UGC*, vol. 1, no. 2, pp. 45–54, 2023.
- [55] M. González, "Modelos de Optimización Para la Planificación de Limpiezas en Parques Solares Fotovoltaicos." Pontificia Universidad Católica de Chile (Chile), 2022.
- [56] L. A. Bargaran Vásquez, "Diseño de sistema automatizado de monitoreo y control con telemetría para mantenimiento preventivo de sistemas fotovoltaicos en las industrias de 3 a 50 kW Lambayeque-Perú," 2021.
- [57] M. Millendorf, E. Obropta, and N. Vadhavkar, "Infrared solar module dataset for anomaly detection," in *Proc. Int. Conf. Learn. Represent*, 2020.
- [58] M. Millendorf, E. Obropta, and N. Vadhavkar, "Infrared Solar Modules." Accessed: Oct. 13, 2023. [En línea]. Disponible en: <https://github.com/RaptorMaps/InfraredSolarModules>
- [59] "Alexnet Architecture Implementation," *OVHcloud*. p. Jupyter Notebook Viewer. Accedido: Oct. 26, 2023. [En línea]. Disponible en: https://nbviewer.org/github/animikhaich/AlexNet-Tensorflow/blob/main/AlexNet_Prototype_Model.ipynb
- [60] P. E. Rauber, S. G. Fadel, A. X. Falcao, and A. C. Telea, "Visualizing the hidden activity of artificial neural networks," *IEEE Trans. Vis. Comput. Graph.*, vol. 23, no. 1, pp. 101–110, 2016.
- [61] M. A. D. S. Lopes, A. D. D. Neto, and A. D. M. Martins, "Parallel t-sne applied to data visualization in smart cities," *IEEE Access*, vol. 8, pp. 11482–11490, 2020.
- [62] S. Raschka, "Model evaluation, model selection, and algorithm selection in machine learning," *arXiv Prepr. arXiv1811.12808*, 2018.

ANEXOS

Anexo 1. Estructura y principio de funcionamiento de una celda fotovoltaica.



Anexo 2. Generadores fotovoltaicos, sus componentes y tipos.



Anexo 3. Esquema del modelo CNN propuesto basado en la arquitectura AlexNet.

